

VYSOKÁ ŠKOLA BÁŇSKÁ – TECHNICKÁ UNIVERZITA OSTRAVA  
EKONOMICKÁ FAKULTA

KATEDRA FINANCÍ

Predikce úpadku firem pomocí scoringového modelu

Forecasting firm's bankruptcy by scoring model

Student:

Bc. Eva Slivková

Vedoucí diplomové práce:

Ing. Jiří Valecký, Ph.D.

Ostrava 2011

VŠB - Technická univerzita Ostrava  
Ekonomická fakulta  
Katedra financí

## Zadání diplomové práce

Student: **Bc. Eva Slivková**  
Studijní program: N6202 Hospodářská politika a správa  
Studijní obor: 6202T010 Finance  
Specializace: 00 Finance  
Téma: **Predikce úpadku firem pomocí scoringového modelu**  
**Forecasting firm's bankruptcy by scoring model**

Zásady pro vypracování:

1. Úvod
  2. Deskripce finanční analýzy
  3. Charakteristika predikčních modelů
  4. Stanovení predikčního modelu úpadku
  5. Závěr
- Seznam použité literatury  
Seznam zkratk  
Prohlášení o využití výsledků diplomové práce  
Přílohy

Seznam doporučené odborné literatury:

CRAMER, J. S. *Logit Models from Economics and Other Fields*. 2nd ed. Cambridge: Cambridge University Press, 2003. 184 s. ISBN 0521815886.  
GOURIEROUX, CH.; JASIAK, J. *The Econometrics of Individual Risk: Credit, Insurance, and Marketing*. 1st ed. New Jersey: Princeton University Press, 2007. 256 s. ISBN 0691120668.  
HOSMER, D. W.; LEMESHOW, S. *Applied Logistic Regression*. 2nd ed. New York: Wiley-Interscience, 2000. 392 s. ISBN 0471356328.


Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.


Vedoucí diplomové práce: **Ing. Jiří Valecký, Ph.D.**

Datum zadání: 26.11.2010

Datum odevzdání: 29.04.2011



  
Ing. Iveta Ratmanová, Ph.D.  
vedoucí katedry

  
prof. Dr. Ing. Dana Dluhošová  
děkanka fakulty

Místopřísežně prohlašuji, že jsem celou práci, včetně všech příloh, vypracovala samostatně.

V Ostravě dne 29. dubna 2011

---

podpis studenta

Tato diplomová práce vznikla za finanční podpory Studentské grantové soutěže EkF, VŠB – TU Ostrava v rámci projektu SP/2010112 a SP2011/38 Odhad a predikce individuálních rizik ve finančních institucích.

## OBSAH

1.	ÚVOD .....	1
2.	DESKRIPCE FINANČNÍ ANALÝZY .....	3
2.1.	Členění finanční analýzy .....	3
2.2.	Fáze finanční analýzy .....	3
2.3.	Zdroje informací pro finanční analýzu .....	4
2.4.	Účetní výkazy .....	5
2.4.1.	Rozvaha podniku .....	5
2.4.2.	Výkaz zisku a ztráty .....	5
2.5.	Metody finanční analýzy .....	6
2.5.1.	Horizontální analýza .....	7
2.5.2.	Vertikální analýza .....	7
2.5.3.	Analýza rozdílových ukazatelů .....	8
2.5.4.	Analýza poměrových ukazatelů .....	8
3.	CHARAKTERISTIKA PREDIKČNÍCH MODELŮ .....	16
3.1.	Ratingové modely .....	16
3.2.	Scoringové modely .....	17
3.3.	Metody tvorby predikčních modelů .....	18
3.3.1.	Diskriminační analýza .....	18
3.3.2.	Regresní analýza .....	20
3.4.	Logistická regrese .....	23
3.4.1.	Binární vysvětlovaná proměnná .....	24
3.4.2.	Vysvětlující proměnné .....	26
3.4.3.	Odhad koeficientů .....	26
3.4.4.	Testování významnosti koeficientů .....	28
3.4.5.	Stavba modelu .....	31

3.4.6.	Hodnocení výsledného modelu.....	31
3.5.	Vybrané predikční modely.....	34
3.5.1.	Bonitní modely .....	34
3.5.2.	Bankrotní modely .....	35
4.	STANOVENÍ PREDIKČNÍHO MODELU ÚPADKU.....	38
4.1.	Finanční analýza firem.....	38
4.2.	Jednorozměrná analýza.....	39
4.3.	Vícerozměrná analýza.....	42
4.4.	Ověření linearity logitu .....	43
4.5.	Hodnocení modelu.....	48
4.6.	Ověření modelu.....	54
5.	ZÁVĚR .....	55
	SEZNAM POUŽITÉ LITERATURY .....	57
	SEZNAM TABULEK A OBRÁZKŮ .....	60
	SEZNAM ZKRATEK .....	61
	PROHLÁŠENÍ O POUŽITÍ VÝSLEDKŮ DIPLOMOVÉ PRÁCE .....	62
	PŘÍLOHY .....	63

## 1. ÚVOD

Predikční modely jsou dnes velmi oblíbeným nástrojem pro predikci téměř čehokoli. Jejich vlastností se využívá v různých oblastech společenského života, zejména v lékařství, sociologii, politice, marketingovém výzkumu, ekonomice apod. Právě ve finanční oblasti zastávají důležitou a nezastupitelnou roli při investičním rozhodování. Investoři poskytující kapitál oprávněně vyžadující spolehlivé informace o bonitě a finančním zdraví svých potenciálních klientů a především o možných budoucích negativních změnách v jejich hospodaření. Právě na ně by měly správně fungující predikční modely včas upozornit, aby nedošlo u investorů a věřitelů k finančním ztrátám. Na paměti je však třeba mít, že žádný z již existujících modelů nefunguje se stoprocentní spolehlivostí a je proto třeba brát je s určitou rezervou. Při aplikaci bychom se neměli spoléhat pouze na jeden jediný predikční model, ale doplnit jej dalším, popřípadě zvolit jinou doplňkovou metodu.

Za hlavní cíl této diplomové práce lze považovat vytvoření fungujícího scoringového modelu, který by s co možná největší spolehlivostí predikoval možný úpadek firmy. Model je vytvořen metodou logistické regrese, stavebním kamenem však je rozsáhlá finanční analýza, která analyzuje hospodaření téměř čtyř set českých společností, zejména akciových společností a společností s ručením omezeným, a to za rok 2008.

Diplomová práce je složená ze dvou základních částí, části teoretické a části praktické, které se dále člení na celkem pět kapitol. První kapitolou je úvod se stručným popisem obsahem práce, druhou kapitolou je deskripce finanční analýzy. Tato kapitola popisuje podstatu finanční analýzy a jednotlivé metody jejího výpočtu se zaměřením na poměrovou analýzu. Další kapitola je věnována predikčním modelům, jejich rozdělení na ratingové a scoringové. V převážné části této kapitoly jsou popisovány jednotlivé metody tvorby modelů, zejména diskriminační analýza, regresní analýza a její specifická podoba – logistická regrese. V závěru kapitoly jsou rovněž zmíněny vybrané predikční modely. Z oblasti hodnocení bonity je to Index Bonity, za bankrotní modely je to Altmanovo Z-skóre.

Ve čtvrté kapitole práce jsou uvedeny postupy a výsledky, kterých bylo při tvorbě modelu metodou logistické regrese pomocí statistického programu STATA dosaženo. Čtvrtá kapitola tak představuje aplikační část celé práce a staví na

teoretických základech předchozích kapitol. Poslední kapitolou je závěr, který shrnuje dosažené výsledky a to jak numerické, tak teoretické.



## **2. DESKRIPTCE FINANČNÍ ANALÝZY**

Ve druhé kapitole diplomové práce najdeme deskripci finanční analýzy. Jsou zde uvedena všechna podstatná fakta týkající se jejího členění, zmíněny jsou fáze finanční analýzy, zdroje informací včetně jednotlivých účetních výkazů. Podstatná část kapitoly je věnována metodám finanční analýzy se zaměřením na poměrovou analýzu.

Finanční analýza je nástrojem diagnózy ekonomických systémů, umožňuje nám nejen odhalovat působení ekonomických i neekonomických faktorů, ale i odhadovat jejich budoucí vývoj. V hodnocení finančního zdraví podniku zastupuje finanční analýza důležité postavení, a to z důvodu vysoké proměnlivosti ekonomických dat, jejich obtížného zpracování, neexistence obecně platných hodnot ukazatelů a teoretických modelů úspěšných společností.

Finanční analýza je oblast, která představuje významnou součást finančního řízení podniku, neboť zajišťuje zpětnou vazbu mezi předpokládaným efektem řídicích rozhodnutí a skutečností. Za hlavní úkol finanční analýzy lze tedy považovat co nejkomplexnější zhodnocení současné finanční situace podniku a odhadnout co nejpřesněji budoucí vývoj. Finanční analýza jako formalizovaná metoda poměří mezi sebou získané údaje a rozšiřuje jejich vypovídací hodnotu, neboť účetní informace samotné poskytují manažerovi jen informace o minulosti bez výhledu do budoucnosti. Vzniká tak neúplný obraz o finanční situaci podniku, jehož nedostatky kompenzuje právě finanční analýza.

### **2.1. Členění finanční analýzy**

Základní dělení finanční analýzy je na externí a interní, přičemž externí finanční analýza vychází z veřejně dostupných informací, interní finanční analýza se naopak opírá o poznatky zjištěné rozbořením hospodaření podniku, při kterém má analytik k dispozici veškeré údaje týkající se finančního, manažerského a nákladového účetnictví, a dále statistická a jiná data.

### **2.2. Fáze finanční analýzy**

Finanční analýza probíhá v několika na sebe navazujících fázích, kterými dle Dluhošová (2010) jsou:

- diagnóza základních indikátorů finanční situace,

- hlubší rozbor příčin zjištěného stavu,
- identifikace hlavních faktorů nežádoucího vývoje,
- návrh opatření.

### 2.3. Zdroje informací pro finanční analýzu

K vytvoření správné finanční analýzy jsou zapotřebí kvalitní zdroje informací. Máme-li špatné podklady, tak ani ta nejlepší technika či metoda nám nepomůže dosáhnout hodnotných výsledků.

Jako základní zdroje informací potřebných k sestavení finanční analýzy jsou nejčastěji uváděny následující:

- *výkazy finančního účetnictví,*
- *výkazy vnitropodnikového účetnictví.*

V úvahu se berou i další relevantní informace, které lze shrnout do následujících okruhů:

- *finanční informace,*
- *kvantifikovatelné nefinanční informace,*
- *nekvantifikovatelné informace.*

*Výkazy finančního účetnictví* lze označit za externí výkazy, neboť jejich údaje slouží především externím uživatelům, kterými mohou být investoři, věřitelé a banky, konkurence, stát atd. Výkazy podávají přehled o stavu a struktuře majetku a zdrojích jeho krytí (rozvaha), o tvorbě a užití výsledků hospodaření (výkaz zisku a ztráty) a v neposlední řadě taktéž o pohybu peněžních toků (výkaz cash flow).

*Výkazy vnitropodnikového účetnictví*, zvané též jako interní, obsahují informace veřejnosti nepřístupné. Výkazy nepodléhají žádné jednotné metodické úpravě a každý podnik si je tvoří sám podle svých potřeb. Příkladem mohou být výkazy o spotřebě nákladů v jednotlivých střediscích nebo na jednotlivé výkony apod.

*Finanční informace* zahrnují informace z vnitřních zdrojů, jako jsou účetní výkazy finančního a vnitropodnikového účetnictví, výroční zprávy, informace finančních analytiků a manažerů podniku, a dále vnější finanční informace jako burzovní zpravodajství či roční zprávy emitentů veřejně obchodovatelných cenných papírů apod.

*Kvantifikovatelné nefinanční informace* obsahují oficiální ekonomické a podnikové statistiky produkce, prodeje, zaměstnanosti, podnikové plány, cenové a nákladové kalkulace a další podnikové evidence.

Mezi *nekvantifikovatelné informace* řadíme informace z odborného tisku, komentáře manažerů, zprávy vedoucích pracovníků, auditorů, prognózy atd.

## **2.4. Účetní výkazy**

Důležitým podkladem pro sestavení finanční analýzy jsou účetní výkazy, které najdeme v účetní závěrce společnosti. Aby byly účetní výkazy výchozím a základním zdrojem informací pro finanční analýzu, musí věrně odrážet pohyb podnikových financí, znázorňovat skutečnou situaci ve firmě. Ve výroční zprávě podniku nalezneme zpravidla rozvahu (bilanci) podniku, výkaz zisku a ztráty podniku a přílohu.

### **2.4.1. Rozvaha podniku**

Účelem rozvahy je přehledně znázornit stav majetku a zdrojích krytí tohoto majetku společnosti k určitému datu, obvykle k poslednímu dni hospodářského roku podniku. Jedná se o dokument stavový, to znamená, že tok financí ve firmě během roku vyčíslit nemůžeme. Tyto informace jsou obsaženy ve výkazu zisku a ztráty společnosti.

Jako slabá stránka bilance se uvádí, že nereflektuje přesně současnou hodnotu podniku. Problém tkví v tom, že účetní standardy používají často jako základ pro ohodnocení aktiv a pasiv historickou hodnotu. K určení realistické hodnoty pak musí být použit odhad, přesto dochází ke zkreslení situace. Další překážkou bránící objektivitě bilance jsou položky, které ačkoli mají určitou „vnitřní“ hodnotu, tak nejsou součástí výkazu. Důvodem je potíže s jejich oceněním, příkladem jsou lidské zdroje firmy, zkušenosti a kvalifikace zaměstnanců atd.

### **2.4.2. Výkaz zisku a ztráty**

Výkaz zisku a ztráty slouží ke zjišťování výše a způsobu tvorby složek výsledku hospodaření. Výkaz nám podává přehled o nákladech a výnosech společnosti během určitého období. Rozdíl mezi výnosy a náklady pak tvoří zisk, respektive ztrátu za běžné účetní období.

K absenci slabých stránek nedochází ani u tohoto výkazu. Výsledek hospodaření za účetní období jakožto výsledná položka účetního výkazu není roven čisté hotovosti vytvořené firmou za dané účetní období a nevyčísluje skutečný hotovostní příjem. Nákladové a výnosové položky se totiž neopírají o skutečné hotovostní toky (příjmy a výdaje), a proto ani výsledný čistý zisk nereflektuje skutečnou dodatečnou hotovost získanou hospodařením firmy v daném období, blíže viz Blaha a Jindřichovská (2006).

## **2.5. Metody finanční analýzy**

Metody finanční analýzy nejsou žádným způsobem kodifikovány, proto se v literatuře často setkáváme s rozlišnou terminologií, dokonce i s různými postupy výpočtů stejných ukazatelů a následně i interpretací výsledků.

Klasická finanční analýza se skládá ze dvou vzájemně propojených částí, viz Sedláček (2007):

- kvalitativní, tzn. **fundamentální analýzy**,
- kvantitativní, tzn. **technické analýzy**.

### **Fundamentální analýza podniku**

Pro sestavení fundamentální analýzy jsou zapotřebí rozsáhlé znalosti vzájemných souvislostí mezi ekonomickými a neekonomickými jevy, dále zkušenosti odborníků, jejich subjektivní odhady i cit pro situace a jejich trendy.

Fundamentální analýza využívá komparativní analýzu založenou převážně na verbálním hodnocení. Patří zde např. SWOT analýza, metoda kritických faktorů úspěšnosti, metoda analýzy portfolia dvou dimenzí a další.

Kvůli obtížnosti této kvalitativní analýzy se většina literatury věnuje spíše kvantitativní analýze. Faktem ale je, že fundamentální analýza tvoří základní rámec pro technickou finanční analýzu.

### **Technická analýza podniku**

Kvantitativní analýza na rozdíl od kvalitativní analýzy používá matematických, statistických a dalších algoritmizovaných metod, kterými může kvantitativně zpracovat ekonomická data a následně je kvalitativně posoudit.

Podle účelu, ke kterému analýza slouží, a podle dat, která používá, se rozlišuje:

- analýza absolutních dat (stavových i tokových),

- analýza trendů (horizontální analýza),
  - procentní rozbor (vertikální analýza),
- analýza rozdílových ukazatelů,
- analýza poměrových ukazatelů,
  - rentability,
  - aktivity,
  - zadluženosti,
  - likvidity,
  - kapitálového trhu,
  - provozní činnosti,
  - cash flow,
- analýza soustav ukazatelů,
  - pyramidové rozklady,
  - bankrotní a bonitní modely,
  - ekonomická přidaná hodnota,
  - matematicko-statistické metody a další.

V této práci budou popsány jen některé z výše zmíněných metod, konkrétně horizontální analýza, vertikální analýza, analýza rozdílových ukazatelů, poměrové ukazatele rentability, aktivity, zadluženosti a likvidity.

### **2.5.1. Horizontální analýza**

Název horizontální analýzy je odvozen od postupu jejího výpočtu, při kterém se sledují změny jednotlivých položek v řádcích rozvahy nebo výkazu zisku a ztráty v čase (obvykle retrospektivně za tři až deset let). Jedná se o změny absolutní nebo relativní.

Horizontální analýza se běžně používá k zachycení vývojových trendů ve struktuře majetku i kapitálu podniku. Lze o ní říci, že se jedná o nejčastěji používanou a nejjednodušší metodou při vypracování zpráv o hospodářské situaci podniku a o jeho minulém i budoucím vývoji.

### **2.5.2. Vertikální analýza**

Vertikální analýza neboli analýza struktury se zaměřuje na analýzu účetních výkazů pomocí procentního vyjádření jednotlivých komponent na zvoleném základu.

Název je opět odvozen od postupu výpočtu, tedy seshora dolů v jednotlivých letech. Jako základ pro procentní vyjádření je u výkazu zisku a ztráty obvykle velikost tržeb a v bilanci hodnota celkových aktiv, případně dílčích složek podniku. Výhodou je, že analýzu lze použít pro srovnání jak v čase, tak v prostoru (srovnání různých firem).

### **2.5.3. Analýza rozdílových ukazatelů**

Rozdílové ukazatele jsou označovány jako fondy finančních prostředků sloužící k analýze a řízení finanční situace firmy. Fond je přitom chápan jako shrnutí určitých stavových ukazatelů vyjadřujících aktiva nebo pasiva, respektive jako rozdíl mezi souhrnem určitých položek krátkodobých aktiv a krátkodobých pasiv.

Jedním z nejpoužívanějších je ukazatel majetkově-finanční stability tzv. čistý pracovní kapitál (ČPK), který se vypočte jako rozdíl mezi celkovými oběžnými aktivy a celkovými krátkodobými dluhy.

### **2.5.4. Analýza poměrových ukazatelů**

Poměrová analýza je nejběžnějším nástrojem finanční analýzy, neboť umožňuje získat rychlý a nenákladný obraz o základních finančních charakteristikách podniku. Poměr (podíl) představuje vztah jednoho čísla k druhému. Výhodou poměrové analýzy je, že redukuje hrubé údaje lišící se podle velikosti firem na společnou a tudíž i komparativní bázi. Jedná se o nejrozzumnější způsob jak srovnávat aktuální finanční informace firmy s jejími historickými daty anebo s daty jiných společností, na jejichž velikosti víceméně nezáleží.

Poměrových ukazatelů existuje ve finanční analýze mnohem více, než je v této práci uvedeno. V podstatě můžeme porovnávat jakékoli dva údaje z finančních výkazů, důležitý však je dobrý komentář a srovnatelnost dat, ať už srovnáváme finanční ukazatele v čase v rámci jedné firmy, nebo jde o mezipodnikové srovnání.

Pro tuto diplomovou práci jsou výsledné hodnoty poměrových ukazatelů vstupními daty pro tvorbu predikčního modelu úpadku firem.

### **Ukazatele rentability**

Ukazatel rentability nám vypovídá o rentabilitě vloženého kapitálu. Ta je obecně definována jako poměr zisku a vloženého kapitálu, který může mít,

viz Dluhošová (2010), tři různé formy, podle které rozlišujeme tyto ukazatele: *rentabilita aktiv* (Return on Assets, ROA), *rentabilita vlastního kapitálu* (Return on Equity, ROE), *rentabilita dlouhodobě investovaného kapitálu* (Return on Capital Employment, ROCE).

#### *RENTABILITA AKTIV – Return on Assets – ROA*

Ukazatel rentability celkových vložených aktiv poměřuje zisk s celkovými aktivy vloženými do podnikání bez ohledu na to, z jakých zdrojů jsou financována. Použijeme-li pro výpočet *EBIT*, pak ukazatel měří hrubou produkční sílu aktiv podniku před odpočtem daní a nákladových úroků. Výhodou tohoto ukazatele je možnost jeho použití při porovnávání podniků s rozdílnými daňovými podmínkami a s různým podílem dluhu ve finančních zdrojích. Vzorec pro výpočet rentability aktiv vypadá takto

$$ROA = \frac{EBIT}{aktiva}, \quad (2.1)$$

kde *EBIT* je zisk před úhradou úroků a daní.

Do čitatele můžeme však dosadit i jiný typ zisku, např. tzv. *EBITDA*, což je zisk před úhradou úroků, daní a odpisů. *EBITDA* vyčísluje celkový finanční efekt generovaný aktivy firmy. Vzorec je pak dán poměrem

$$ROA = \frac{EBITDA}{aktiva}. \quad (2.2)$$

#### *RENTABILITA VLASTNÍHO KAPITÁLU – Return on Equity – ROE*

Míra výnosnosti vlastního kapitálu je ukazatelem, jímž vlastníci zjišťují, zda jejich kapitál přináší dostatečný výnos, zda je využit s intenzitou odpovídající velikosti jejich investičního rizika. Pro investora je důležité, aby ukazatel *ROE* byl vyšší než úroky, které by získal při jiné formě investování. Takovýto požadavek lze považovat za oprávněný, neboť investor nese poměrně vysoké riziko související s podnikáním. Z toho vyplývá, že cena vlastního kapitálu placená formou dividendy či podílu na zisku je vyšší než cena cizího kapitálu placená ve formě úroku. Jinak řečeno, vlastní kapitál je dražší než kapitál cizí. Tento fakt je třeba brát v úvahu při rozhodování o struktuře zdrojů.

Vzorec pro výpočet rentability vlastního kapitálu je následující

$$ROE = \frac{\text{čistý zisk}}{\text{vlastní kapitál}}. \quad (2.3)$$

## *RENTABILITA DLOUHODOBÝCH ZDROJŮ – Return on Capital Employment – ROCE*

Rentabilita dlouhodobých zdrojů slouží k prostorovému srovnání podniků, zejména k hodnocení monopolních veřejně prospěšných společností. Ukazatelem hodnotíme význam dlouhodobého investování na základě určení výnosnosti vlastního kapitálu spojeného s dlouhodobými zdroji. Investovaný kapitál se vztahuje jen ke zpoplatněnému kapitálu. Vzorec pro výpočet rentability dlouhodobých aktiv je dán následovně

$$ROCE = \frac{EBIT}{\text{dlouhodobé závazky} + \text{vlastní kapitál}} \quad (2.4)$$

## *RENTABILITA TRŽEB – Return on Sales – ROS*

Běžně používaným ukazatelem finanční analýzy, který se používá k mezipodnikovému srovnání a srovnání v čase, je rentabilita tržeb. Ukazatel poměřuje dosažený zisk k tržbám podniku. Do čitatele je přitom vhodné dosazovat buď čistý zisk, nebo provozní zisk, pokud chceme eliminovat vliv zdanění a nákladových úroků. Obecně platí, že vyšší hodnota ukazatele svědčí o dobré práci managementu a dobrém jménu firmy. Rentabilita tržeb se vypočte následovně

$$ROS = \frac{\text{čistý zisk}}{\text{tržby}} \quad (2.5)$$

## **Ukazatele aktivity**

Jako ukazatele aktivity jsou souhrnně nazývány ukazatele relativní vázanosti kapitálu v různých formách aktiv. Ukazatele měří, jak efektivně podnik hospodaří se svými aktivy. Jedná se zejména o ukazatele doby obratu nebo obratovosti, které jsou využívány pro řízení aktiv.

## *OBRÁTKA CELKOVÝCH AKTIV – Total assets turnover ratio*

Obrátka celkových aktiv nám udává počet obrátek za daný časový interval, většinou rok. Lépe řečeno, obrátka aktiv nám říká, jaké je využití celkového majetku podniku. Ukazatel by měl mít rostoucí tendenci, znamená to efektivnější využití majetku. Vzorec pro výpočet obratu celkových aktiv bývá znázorněn takto

$$\text{obrátka celkových aktiv} = \frac{\text{tržby}}{\text{aktiva}} \quad (2.6)$$



### *DOBA OBRATU ZÁSOb – Inventory turnover*

Ukazatel doby obratu zásob charakterizuje úroveň běžného provozního řízení. Uvádí průměrný počet dnů, po které jsou zásoby vázány v podnikání do doby jejich spotřeby nebo do doby jejich prodeje. Vzorec pro výpočet doby obratu zásob je

$$\text{doba obratu zásob (dny)} = \frac{\text{zásoby} \cdot 360}{\text{tržby}}. \quad (2.7)$$

### *DOBA OBRATU POHLEDÁVEK – Average collection period*

Ukazatel doby obratu pohledávek vypovídá o strategii řízení pohledávek. Vypočítá se jako poměr průměrného stavu obchodních pohledávek k průměrným denním tržbám na obchodní úvěr. Výsledkem je počet dnů, během nichž je inkaso peněz za každodenní tržby zadrženo v pohledávkách. Po tuto průměrnou dobu musí podnik čekat na inkaso plateb za své již provedené služby. Tento ukazatel je důležitý z hlediska plánování peněžních toků. Vzorec pro výpočet doby obratu pohledávek se vypočte jako

$$\text{doba obratu pohledávek (dny)} = \frac{\text{pohledávky} \cdot 360}{\text{tržby}}. \quad (2.8)$$

### *DOBA OBRATU ZÁVAZKŮ – Payables turnover ratio*

Doba obratu závazků vyjadřuje platební morálku firmy vůči jejím dodavatelům. Udává tedy průměrný počet dnů, než firma splatí faktury dodavatelům. Ukazatel se vypočte jako poměr průměrného stavu závazků z obchodního styku k průměrným denním tržbám na obchodní úvěr.

Vzorec pro výpočet doby obratu závazků je dán vztahem

$$\text{doba obratu závazků (dny)} = \frac{\text{závazky} \cdot 360}{\text{tržby}}. \quad (2.9)$$

### **Ukazatele zadluženosti**

Podniková aktiva jsou financována finančními zdroji, a to buď vlastním, nebo cizím kapitálem. Právě ukazatele zadluženosti nám znázorňují vztah mezi cizími a vlastními zdroji, měří rozsah, v jakém společnost používá k financování dluhy. Zadluženost není pouze negativní charakteristikou podniku, jak je již výše zmíněno, vlastní kapitál je dražší než kapitál cizí, takže vyšší zadluženost může pozitivně přispět k celkové rentabilitě, a tím i k vyšší tržní hodnotě podniku. Současně si musíme dát pozor na zvyšující se riziko finanční nestability.

### *CELKOVÁ ZADLUŽENOST – Dept ratio*

Celková zadluženost neboli ukazatel věřitelského rizika se vypočte jako podíl celkových dluhů k celkovým aktivům podniku. Obecně platí, že pokud je podíl vlastního kapitálu ve firmě vyšší, tím vyšší je i tzv. bezpečnostní polštář proti ztrátám věřitelů v případě zrušení společnosti. Z toho plyne, že věřitelé (zvláště ti dlouhodobí jako jsou kupříkladu komerční banky) preferují nižší hodnotu tohoto ukazatele. Výpočet celkové zadluženosti je dán poměrem

$$\text{celková zadluženost} = \frac{\text{cizí kapitál}}{\text{aktiva}}. \quad (2.10)$$

### *KVÓTA VLASTNÍHO KAPITÁLU – Equity ratio*

Kvóta vlastního kapitálu slouží jako doplněk k ukazateli celkové zadluženosti podniku. Oba ukazatelé tudíž dohromady dávají součet jedna. Je vyjádřením finanční nezávislosti podniku a obecně platí, že při zvyšování tohoto ukazatele dochází k upevňování finanční stability. Vzorec pro výpočet kvóty vlastního kapitálu je následující

$$\text{kvóta vlastního kapitálu} = \frac{\text{vlastní kapitál}}{\text{aktiva}}. \quad (2.11)$$

### *ÚROKOVÉ ZATÍŽENÍ*

Ukazatel úrokového zatížení nám říká, jakou část vytvořeného efektu (zisku) nám odčerpají nákladové úroky. Pokud podnik dosahuje dlouhodobě nízkého úrokového zatížení, může si dovolit vyšší podíl cizích zdrojů. Vzorec pro výpočet úrokového zatížení se obecně vyjádří

$$\text{úrokové zatížení} = \frac{\text{úroky}}{\text{EBIT}}. \quad (2.12)$$

### *BĚŽNÁ ZADLUŽENOST – Current dept ratio*

Úkolem běžné zadluženosti je poměřit krátkodobý cizí kapitál s celkovými aktivy podniku. Čítec zahrnuje krátkodobé závazky, běžné bankovní úvěry, pasivní přechodné a dohadné položky. Vzorec pro výpočet běžné zadluženosti má následující početní vztah

$$\text{běžná zadluženost} = \frac{\text{krátkodobý cizí kapitál}}{\text{aktiva}}. \quad (2.13)$$

## ÚVĚRY/ PASIVA

Specifickým ukazatelem finanční analýzy je ukazatel, který poměřuje množství přijatých bankovních úvěrů k celkovým pasivům. Můžeme přitom rozlišovat krátkodobé a dlouhodobé úvěry a výpomoci. Nadměrná velikost tohoto ukazatele znamená vysoké riziko pro věřitele, ovšem stanovit optimální hodnotu lze jen stěží. Vztah vypadá následovně

$$\text{úvěry} / \text{pasiva} = \frac{\text{bankovní výpomoci}}{\text{pasiva}}. \quad (2.14)$$

## FINANČNÍ PÁKA – Financial Leverage

Finanční páka nebo také majetkový koeficient je ukazatelem, který poměřuje celková aktiva podniku s vlastním kapitálem. Z dlouhodobého hlediska by měl být ukazatel stabilní, aby byla nalezena rovnováha zdrojů financování potřeb firmy. Jinými slovy jde o nalezení optimální zadluženosti podniku. Výpočet se provádí takto

$$\text{finanční páka} = \frac{\text{aktiva}}{\text{vlastní kapitál}}. \quad (2.15)$$

## STUPEŇ KRYTÍ STÁLÝCH AKTIV

Stupeň krytí stálých aktiv je poměrovým finančním ukazatelem, který nám vypovídá o finanční stabilitě firmy na základě porovnání hodnoty dlouhodobého kapitálu se stálými aktivy. Hodnota ukazatele by měla být minimálně 100%, neboť platí, že veškerá stálá aktiva by měla být financována dlouhodobými zdroji. Výpočet je následující

$$\text{stupeň krytí stálých aktiv} = \frac{\text{dlouhodobý kapitál}}{\text{stálá aktiva}}. \quad (2.16)$$

## ZADLUŽENOST VLASTNÍHO KAPITÁLU – Debt/Equity Ratio

Ukazatel zadluženosti vlastního kapitálu dává do poměru cizí kapitál s vlastním kapitálem. Optimální hodnota zadlužení není přesně specifikována, ale měla by se pohybovat v rozmezí od 80% do 120% u stabilních společností. Podstatnou roli sehrává i to, v jaké fázi vývoje se daná firma nachází. Vzorec pro výpočet je tento

$$\text{zadluženost vlastního kapitálu} = \frac{\text{cizí kapitál}}{\text{vlastní kapitál}}. \quad (2.17)$$

## ÚVĚROVÁ ZADLUŽENOST

Důležitým ukazatelem pro podniky, u kterých významnou část cizích zdrojů tvoří bankovní úvěry, je ukazatel úvěrové zadluženosti, jehož vzorec vypadá následovně

$$\text{úvěrová zadluženost} = \frac{\dot{U}}{\text{vlastní kapitál}}, \quad (2.18)$$

kde  $\dot{U}$  jsou bankovní úvěry.

## Ukazatele likvidity

Likvidita je obecně chápána jako schopnost podniku dostát v určitém čase svých krátkodobých závazků, získat včas dostatek prostředků na provedení potřebných plateb. Ukazatele likvidity podle Sedláčka (2007) poměřují to, čím je možno platit, tím, co je nutno zaplatit. Zabývají se nejlikvidnější částí aktiv podniku a rozdělují se podle likvidnosti položek aktiv dosazovaných do čitatele z rozvahy. Slabou stránkou ukazatelů je, že hodnotí likviditu podle zůstatku finančního majetku, ale ta v daleko větší míře závisí na budoucích cash flow.

### BĚŽNÁ LIKVIDITA – *Current ratio*

Běžná likvidita je poměrně hrubý ukazatel platební schopnosti podniku, neboť měří platební schopnost z hlediska krátkého období. Ukazatel je navíc citlivý na strukturu zásob a na jejich správném ocenění vzhledem k jejich prodejnosti a na strukturu pohledávek k jejich neplacení ve lhůtě či nedobytnosti. Ukazatel běžné likvidity ukazuje, kolikrát pokrývají oběžná aktiva krátkodobé závazky, je stavového charakteru, a proto by měl být jeho vývoj posuzován v čase. Jeho optimální hodnota se pohybuje v rozmezí od 1,5 do 2,5, viz Dluhošová (2010). Vzorec pro výpočet běžné likvidity je interpretován takto

$$\text{oběžná likvidita} = \frac{OA}{\text{krátkodobé závazky}}, \quad (2.19)$$

kde  $OA$  jsou oběžná aktiva.

### POHOTOVÁ LIKVIDITA – *Quick ratio*

Ukazatel pohotové likvidity řeší nedostatky ukazatele běžné likvidity tím, že z oběžných aktiv vylučuje zásoby a ponechává v čitateli jen peněžní prostředky,

krátkodobé cenné papíry a krátkodobé pohledávky. Hodnota ukazatele by se měla pohybovat v horizontu od 1 do 1,5, při poklesu pod 1 je narušena likvidita podniku. Růst ukazatele signalizuje zlepšení finanční a platební situace. Vzorec pro výpočet pohotové likvidity je poměrem následujícího čitatele a jmenovatele

$$\text{pohotová likvidita} = \frac{OA - \text{zásoby}}{\text{krátkodobé závazky}}. \quad (2.20)$$

#### *OKAMŽITÁ LIKVIDITA – Cash ratio*

Ukazatel okamžité likvidity vykazuje schopnost podniku hradit právě splatné dluhy. Do čitatele se dosazují ty nejlikvidnější prostředky, tedy peníze v hotovosti a na účtech, jejich ekvivalenty, kterými jsou volně obchodovatelné krátkodobé cenné papíry, splatné dluhy, směnečné dluhy a šeky. Likvidita je zajištěna při hodnotě ukazatele alespoň 0,2, přičemž je třeba brát v úvahu nestabilitu tohoto ukazatele. Vzorec pro výpočet okamžité likvidity je níže uvedený vztah

$$\text{okamžitá likvidita} = \frac{\text{pohotové peníze a ekvivalenty}}{\text{okamžitě splatné dluhy}}. \quad (2.21)$$

#### *POMĚROVÝ UKAZATEL LIKVIDITY*

Poměrový ukazatel likvidity nám ukazuje, z jakých zdrojů jsou financována dlouhodobá fixní aktiva. Je-li totiž ukazatel záporný, svědčí to o tom, že k financování stálých aktiv jsou použity krátkodobé závazky, což je špatně. Ve finančně zdravém podniku se hodnota ukazatele pohybuje od 30% do 50%. Poměrový ukazatel likvidity lze vypočítat takto

$$\text{poměrový ukazatel likvidity} = \frac{OA - \text{krátkodobé závazky}}{OA}. \quad (2.22)$$

#### *PŘIDANÁ HODNOTA/TRŽBY*

Zajímavým ukazatelem finanční analýzy je ukazatel poměřující přidanou hodnotu (*PH*) k tržbám. Konkrétní doporučená hodnota neexistuje, vždy záleží na předmětu podnikání daného podniku. Optimální by však bylo, kdyby hodnota ukazatele rostla (za podmínky neklesajících tržeb), nebo zůstala konstantní. Výpočetní vztah je tento

$$PH / \text{tržby} = \frac{PH}{\text{tržby}}. \quad (2.23)$$

### 3. CHARAKTERISTIKA PREDIKČNÍCH MODELŮ

V této kapitole je blíže přiblížena problematika ratingových a scoringových predikčních modelů, převážná část kapitoly je pak věnována metodám, které analytici využívají při tvorbě těchto modelů. V závěru kapitoly jsou zmíněny vybrané predikční modely – Index Bonity z oblasti bonitních modelů a Altmanovo Z-skóre za modely bankrotní.

Oblast, ve které se dnes používají predikční modely, je velmi široká. Vždy však záleží na tom, co je předmětem predikce, čili to, co má být predikováno. Ve finanční oblasti tímto předmětem nejčastěji bývá bonita klienta a to nejen v případě, kdy klient žádá o poskytnutí úvěru v některé z finančních institucí, dále je to finanční zdraví podniku, či pravděpodobnost finanční tísně.

V hodnocení určitého subjektu rozlišujeme rating a scoring. Oba přístupy jsou si podobné a bývají často mylně zaměňovány, avšak rating je mnohem složitější na zpracování, neboť je zapotřebí větší množství kvalitních vstupních dat.

#### 3.1. Ratingové modely

Ještě v nedávné době nebyl pojem rating v české ekonomice na rozdíl od zahraničních zemí příliš významný. Dnes se běžně používá v oblasti kapitálového trhu i bankovního sektoru. Rating představuje komplexní hodnocení určitého subjektu s cílem odhadnout jeho současnou a budoucí schopnost splácet včas a řádně své závazky vyplývající z emise cenných papírů nebo i jiné závazky, ke kterým se subjekt zavázal. Rating nejčastěji provádí nezávislá soukromá ratingová agentura, která dlužníkovi udělí ratingovou známku, jež vyjadřuje schopnost subjektu dostát svých dlužnických závazků. Úkolem ratingu je na jedné straně podat informace poskytovatelům cizího kapitálu, na straně druhé rating umožňuje zviditelnění klientů, kteří se snaží získat levnější zdroje financování, viz Sedláček (2007).

V minulosti se rating vztahoval pouze na hodnocení rizik v souvislosti s dluhopisovými instrumenty. S vývojem kapitálového trhu a zvyšujícími se požadavky investorů se ratingové agentury postupně zaměřily i na další oblasti hodnocení. Ratingové hodnocení se dnes provádí např. u státu, měst, podniků, bank atd.

Podle předmětu ratingu rozlišujeme např. rating cenných papírů s pevným výnosem, rating syndikovaného dluhu, rating směnek, rating strukturovaného

financování a projektového financování. Z hlediska cílového trhu a denominace dluhu rozlišujeme mezinárodní rating v cizí měně, mezinárodní rating v korunách anebo lokální rating, který je méně náročný na zpracování a svou cenou je dostupnější i středním podnikům. Dalším dělením ratingu je rating obchodní a investiční, z hlediska času pak krátkodobý a dlouhodobý rating.

Rating, který slouží managementu společnosti jako nástroj pro zlepšení řízení, avšak veřejnosti přístupný není, označujeme jako vnitřní rating. Naopak externí rating slouží investorům, kteří zamýšlejí investici v podobě zapůjčení kapitálu dané společnosti, tak obchodním partnerům, poradenským společnostem a celé široké veřejnosti. O tento rating může požádat nejen společnost, která má být předmětem hodnocení, ale kdokoli jiný.

Náročnost ratingu spočívá především v hodnocení velkého množství informací a to jak interních, tak externích. Na základě provedené fundamentální analýzy a vyhodnocení veškerých známých rizik je pak agenturou udělena ratingová známka, viz Sedláček (2007).

Nejznámější ratingové agentury světa jsou Moody's, Standard & Poor's a Fitch, v České republice pak působí společnost CRA Rating Agency, která poskytuje ratingovou známku podnikům, městům a finančním institucím. Tyto renomované agenturní společnosti používají profesionální modely, které jsou jejich duševním vlastnictvím.

Příkladem ratingového modelu, který však v Evropě není příliš známý, je Mertonův model kreditního rizika. Model odhaduje pravděpodobnost defaultu firmy na základě volatility a tržní hodnoty akcií daného podniku. V České republice se tento model pro predikci prakticky nepoužívá, neboť náš poměrně mladý akciový trh neposkytuje pro predikci dostatečné údaje.

### **3.2. Scoringové modely**

Scoring je další způsob, jak vyhodnotit finanční a ekonomickou situaci subjektu. Scoringové modely jsou založeny na kvantitativní finanční analýze dat, které hodnocený subjekt předkládá za minulá hospodářská období. Kvalitativní data mohou být rovněž použita, avšak musí být nejdříve dle určitých obecně platných pravidel

transformována na data kvantitativní. Tento předpoklad pak snižuje možnost subjektivního úsudku o hodnoceném podniku.

Scoring se používá zejména ve finančním sektoru a pojišťovnictví, kde slouží k detekci pojišťovacích podvodů. V bankovníctví pak scoring slouží k určení klientů, u kterých hrozí riziko, že by přestali splácet úvěr, který jim byl poskytnut.

Nejpoužívanějším scoringem je kreditní scoring, který předvídá, zda klient neztratí svou schopnost splácet úvěr. Používá se ještě před schválením žádosti o poskytnutí půjčky. Metody kreditního scoringu jsou standardní součástí řízení rizik finančních institucí. Dalšími typy scoringu jsou aplikační a behaviorální scoring.

Na základě dostupných informací o chování klientů, kterým byl poskytnut v minulosti úvěr, si finanční instituce vytváří své predikční scoringové modely. Ty následně aplikují u nových klientů, viz Vraná (2009).

Scoring je na rozdíl od ratingu mnohem více používáný a to především pro svou jednoduchost, časovou nenáročnost a finanční dostupnost. Hodnocení subjektu ratingem se využívá zejména v případě nestandardní nebo významné dlouhodobé zakázky.

### **3.3. Metody tvorby predikčních modelů**

Každý predikční model je založen na vztahu mezi závislou vysvětlovanou proměnnou a nezávislými vysvětlujícími proměnnými (případně jednou nezávislou vysvětlující proměnnou). Cílem je analyzovat vliv vysvětlujících proměnných na proměnnou vysvětlovanou tak, abychom pro objekt s neznámou hodnotou vysvětlované proměnné mohli tuto hodnotu odhadnout. Ke klasifikaci vztahu mezi vysvětlovanou a vysvětlujícími veličinami a pro odhad budoucích hodnot závislé proměnné se používají různé metody, např. diskriminační analýza, lineární regresní analýza, logistická regrese, klasifikační stromy, neuronové sítě a další. Pro odhad predikčního modelu úpadku firem je v této práci použita metoda logistické regrese.

#### **3.3.1. Diskriminační analýza**

Jednou z metod mnohonásobné statistické analýzy je analýza diskriminační. První zmínky o této analýze pochází z roku 1936 a objevily se v pracích R. A. Fishera, který ji aplikoval v oblasti biologie. Postupně se metoda začala používat i v dalších



oblastech společenského života, např. v sociologii, politice, lékařství, bankovníctví, finančníctví atd.

Diskriminační analýza zkoumá závislost mezi jednou závislou kvalitativní veličinou a mezi skupinou kvantitativních nezávislých veličin (tzv. diskriminátory). Úkolem diskriminační analýzy je najít zákonitosti v rozdělení do konečného počtu tříd a stanovit pravidlo, podle kterého zařazujeme nový objekt do konkrétní třídy podle proměnných. Míra variability v rámci jedné třídy má být přitom co nejmenší, meziskupinová variabilita by měla být naopak maximální.

Předpoklady pro použití diskriminační analýzy jsou následující:

- charakteristické znaky jednotlivých prvků musí být kvantitativní,
- žádný ze znaků nesmí být lineární kombinací ostatních znaků (lineární nezávislost),
- vícerozměrné normální rozdělení vstupních dat,
- přesně definované skupiny statistických objektů (expertním posouzením, objektivními metodami, statistickými přístupy),
- existence minimálně dvou skupin, přičemž každá skupina musí být větší než počet diskriminačních proměnných,
- kovarianční matice by měly být podle skupin přibližně stejné, aby bylo možno odvodit Fisherovu diskriminační funkci, viz Stankovičová (2007).

Fisherova lineární diskriminační funkce má tento základní tvar:

$$Z_h = a_{h1}x_1 + a_{h2}x_2 + \dots + a_{hk}x_k \quad (3.1)$$

pro  $h = 1, \dots, s$ , kde  $s = \min(k; q - 1)$  a kde  $k$  značí počet diskriminátorů,  $x_1, x_2, \dots, x_k$  jsou standardizované hodnoty těchto diskriminátorů. Parametry  $Z_i$  značí standardizované klasifikační koeficienty Fisherovy diskriminační funkce  $a^T = [a_1, a_2, \dots, a_k]$ , které získáme tak, že poměr (označeno  $F$ ) rozptylu mezi třídami  $B$  a rozptyl uvnitř tříd  $W$  je maximální, jinými slovy maximalizujeme poměr součtu čtverců mezi třídami k součtu čtverců uvnitř tříd.  $B$  (between-classes variability) je kovarianční matice mezitřídních průměrů a  $W$  (within-classes variability) je celková kovarianční matice uvnitř tříd. Vektor  $a$ , který maximalizuje poměr  $F$ , se dle Stankovičová (2007) určí ze vztahu  $A = W^{-1} \cdot B$ .

Rozlišujeme analytickou úlohu diskriminační analýzy, jejímž úkolem je odvodit diskriminační funkci, která identifikuje existenci statisticky významných rozdílů mezi průměry předem definovaných veličin, a klasifikační úlohu diskriminační analýzy, která na základě  $k$  znaků identifikuje nový objekt do některé z  $q$  skupin.

Asi nejznámějším predikčním modelem, který je založen právě na diskriminační analýze, je Altmanovo Z-skóre. Altmanovu modelu je věnována podkapitola 3.5.2.

### 3.3.2. Regresní analýza

Regresní analýza je označovaná jako statistická metoda, která modeluje závislost jedné nebo několika nejlépe měřitelných spojitých vysvětlovaných náhodných veličin na jedné nebo několika klasicky nenáhodných rovněž měřitelných spojitých vysvětlujících veličinách.

Základní motivací regresní analýzy je snaha a potřeba nepřímo působit na hodnoty vysvětlované proměnné volbou, ovlivňováním nebo aspoň snadnějším odhadem vysvětlujících proměnných. Splnění tohoto úkolu vyžaduje, aby mezi vysvětlovanou veličinou a vysvětlujícími veličinami existoval kvantifikovatelný vztah, neboli matematicky popsatelná závislost vysvětlovaných proměnných na vysvětlující proměnných. Tento vztah má být zobrazen regresním modelem, jehož rozhodující součástí je regresní funkce.

V regresní analýze se klade důraz na to, aby napozorovaná data byla vyrovnána vhodnou matematickou funkcí tak, aby bylo dosaženo maximální shody mezi skutečnými a vyrovnanými hodnotami vysvětlované proměnné. Ve skutečnosti bývají regresní funkce často nelineární, avšak v modelech se pro zjednodušení a snadnější interpretaci výsledků používají lineární regresní funkce.

Regresní funkce je definována jako podmíněná střední hodnota určité náhodné veličiny  $Y$  vzhledem k různým lineárním kombinacím hodnot jiných náhodných proměnných (regresorů)  $x' = (1, x_1, x_2, \dots, x_k)$  s regresními koeficienty  $\beta' = (\beta_0, \beta_1, \dots, \beta_k)$ , tedy

$$E(Y|x) = x' \beta. \quad (3.2)$$

Pracujeme zde s předpokladem, že každá napozorovaná hodnota  $y_i$  vysvětlované proměnné  $Y$  je funkcí modelové hodnoty  $\eta_i$ , obsahující působení kontrolovaných vlivů

vysvětlujících proměnných a hodnoty rušivé složky  $\varepsilon_i$ , zobrazující působení nekontrolovatelných, nepodstatných nebo obecněji neuvažovaných vlivů, viz Hebák (2005). V případě lineárního regresního modelu se pro zjednodušení předpokládá, že vztah mezi modelovou ( $\eta$ ) a nemodelovou složkou ( $\varepsilon$ ) je součtový a lze vyjádřit takto

$$Y = \eta + \varepsilon. \quad (3.3)$$

U lineárního modelu rozlišujeme model obecný, nebo zcela lineární model. V obecném modelu má modelová složka tento tvar

$$\eta = \beta_0 + \beta_1 f_1 + \beta_2 f_2 + \dots + \beta_k f_k, \quad (3.4)$$

kde  $f_1, f_2, \dots, f_k$  jsou libovolné známé funkce původních proměnných  $X_1, X_2, \dots, X_k$ . Důležité je, že funkce  $f_j$  neobsahuje žádné další neznámé parametry, takže při znalosti hodnot původních proměnných není obtížné vypočítat hodnoty nových proměnných.

Zcela lineární regresní model s  $k$  vysvětlujícími proměnnými má obdobný tvar jako model obecný, neboli

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon, \quad (3.5)$$

kde oproti obecnému modelu najdeme i neznámé konstanty, kterými jsou absolutní člen  $\beta_0$  a dílčí regresní koeficienty  $\beta_1, \beta_2, \dots, \beta_k$ . Ačkoli absolutní člen nemá zřejmou věcnou interpretaci, je jeho zařazení v modelu podstatné z důvodu existence nezařazených a neuvažovaných vlivů. Dílčí regresní koeficienty  $\beta_j$  zjednodušeně představují průměrnou změnu  $Y$  při růstu hodnoty proměnné  $X_j$  o jednu měřicí jednotku za předpokladu konstantních ostatních vysvětlujících proměnných. Abychom mohli takto snadno vyčíslit čistý vliv vysvětlující veličiny na vysvětlovanou, musí platit vzájemná nezávislost vysvětlujících proměnných.

Jak obecný, tak zcela lineární model se za splnění určitých podmínek označují jako klasický lineární model. Ten má následující tvar

$$Y = X\beta + \varepsilon. \quad (3.6)$$

Podmínky jsou kladeny na jednotlivé složky modelu, jak na náhodou složku  $\varepsilon$ , tak na matici vysvětlujících proměnných  $X$ , či vektor regresních koeficientů  $\beta$ .

Podmínky jsou tyto<sup>1</sup>:

- $E(\varepsilon_i) = 0$  pro každé  $i=1,2,\dots,n$ . Střední hodnota náhodné složky je nulová. Tato podmínka znamená, že náhodná složka nepůsobí systematickým způsobem na hodnoty vysvětlované proměnné  $Y$ .
- $E(\varepsilon_i) = \sigma^2$  pro každé  $i=1,2,\dots,n$ . Rozptyl náhodné složky je konstantní (hovoříme o tzv. *homoskedasticitě*). Tato podmínka vyjadřuje, že variabilita náhodné složky nezávisí na hodnotách vysvětlujících proměnných a tudíž i podmíněná variabilita vysvětlované proměnné nezávisí na hodnotách vysvětlujících proměnných a je rovna neznámé kladné konstantě  $\sigma^2$ .
- $\text{Cov}(\varepsilon_i, \varepsilon_j) = 0$  pro každé  $i \neq j=1,2,\dots,n$ . Kovariance náhodné složky je nulová. Tedy hodnoty náhodné složky jsou nekorelované a z toho vyplývá i nekorelovanost různých dvojic pozorování vysvětlované proměnné  $Y$ .
- $X$  je nestochastická (nenáhodná) matice. Znamená to tedy, že vysvětlující proměnné jsou nenáhodné.
- Matice  $X$  má plnou hodnost, tedy  $h(X) = k+1 \leq n$  ( $n$  je počet pozorování). Tato podmínka vyžaduje, aby mezi vysvětlujícími proměnnými nebyla funkční lineární závislost, tedy v matici  $X$  nesmí existovat lineárně závislé sloupce. Počet vysvětlujících proměnných nesmí být pochopitelně větší než počet pozorování a v praxi by měl počet pozorování výrazně větší než počet vysvětlujících proměnných.
- $\varepsilon_i$  mají normální rozdělení pro každé  $i=1,2,\dots,n$ . Z této podmínky vyplývá normalita i pro vysvětlovanou proměnnou  $Y$ . Náhodný vektor  $Y$  má potom  $n$ -rozměrné normální rozdělení s vektorem středních hodnot  $X\beta$  a kovarianční maticí  $\sigma^2 I_n$ .
- Parametry  $\beta_j, j=1,2,\dots,k$  mohou nabývat libovolných hodnot. Na vektor  $\beta$  tedy nejsou kladeny žádné omezující podmínky.

---

<sup>1</sup> ŘEZÁNKOVÁ a kol. (2001)

Vektor hodnot vysvětlované proměnné  $y$  má  $n$ -rozměrné normální rozdělení  $N_n(X\beta, \sigma^2 I_n)$  s vektorem středních hodnot  $E(y) = \eta = X\beta$  a kovarianční maticí  $C(y) = \sigma^2 I_n$ .

### 3.4. Logistická regrese

Logistická regrese je rovněž statistickou metodou, která zkoumá vztah mezi vysvětlovanou závislou proměnnou a vysvětlujícími nezávislými proměnnými, avšak na rozdíl od regresní analýzy uvažuje na místě vysvětlované proměnné veličiny dichotomické nebo multinomické, které nabývají jen malý počet obměn. Regresní analýza na místě vysvětlované proměnné předpokládá spojitě veličiny. Logistická regrese je tak speciální metodou regresní analýzy, jejímž úkolem je navrhnout model pro predikci hodnot vysvětlované proměnné na základě pravděpodobnosti zařazení nově příchozí jednotky do skupiny jí podobných jednotek pomocí zjištěných údajů.

Metoda se užívá především v bankovníctví, medicíně, marketingu, ekonomii a v technických nebo přírodních vědách.

Jak již bylo výše zmíněno, logistická regrese uvažuje na místě vysvětlované proměnné veličiny dichotomické či multinomické. Jako multinomické veličiny jsou označovány takové proměnné, které mají více než dvě kategorie. Podle toho, zda lze kategorie seřadit a určit vzdálenost mezi nimi, rozlišujeme data nominální, ordinální a kardinální. Pro tuto práci jsou však předmětem zájmu dichotomické veličiny. Dichotomická nebo také alternativní proměnná je zvláštním typem kategoriální proměnné, která může nabývat pouze hodnot v intervalu od nuly do jedné. Právě podmínka, aby podmíněná střední hodnota vysvětlované proměnné byla větší nebo rovná nule a zároveň byla menší nebo rovná jedné, je základním předpokladem použití logistické regrese oproti klasické regresní analýze, viz Hebák (2007).

Vzhledem k alternativní vysvětlované proměnné nelze při konstrukci logistického regresního modelu vycházet z klasického lineárního modelu, viz (3.6), ale musíme vycházet ze zobecněného lineárního modelu. U zobecněného lineárního modelu nadále platí podmínka nenáhodnosti matice  $X$ , avšak není třeba, aby byla dodržena podmínka týkající se kovarianční matice a náhodné složky  $\varepsilon$ , protože právě tyto podmínky mohou být u alternativní proměnné snadno zpochybnitelné. Použití zobecněného lineárního modelu znamená nalézt vhodnou transformující funkci, která

převěde nevyhovující model na klasický lineární model vyhovující všem stanoveným podmínkám. Onu hledanou transformující funkci získáme úpravou z následující rovnice, která vyjadřuje pravděpodobnostní funkci alternativního rozdělení,

$$P(y | \pi) = \pi^y (1 - \pi)^{1-y}, \quad (3.7)$$

$$P(y | \pi) = \pi^y (1 - \pi)^{1-y} = (1 - \pi) \left( \frac{\pi}{1 - \pi} \right)^y = (1 - \pi) e^{y \cdot \ln \frac{\pi}{1 - \pi}}, \quad (3.8)$$

kde  $\ln \frac{\pi}{1 - \pi}$  vyjadřuje logit (logaritmus šance) neboli onu transformující funkci.

Protože  $\pi \in (0,1)$ , podíl  $\frac{\pi}{1 - \pi}$  může nabýt jakékoli nezáporné hodnoty, logit pak může nabýt jakékoli reálné hodnoty. Použijeme-li logitovou transformaci  $\pi$  v zobecněném lineárním modelu a budeme-li ho postupně upravovat, obdržíme nelineární regresní funkci s  $k$  vysvětlujícími proměnnými, viz Hebák (2007),

$$\text{logit}(\pi) = \ln \frac{\pi}{1 - \pi} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k = x' \beta. \quad (3.9)$$

### 3.4.1. Binární vysvětlovaná proměnná

Má-li vysvětlovaná veličina  $Y$  alternativní rozdělení, tedy  $Y \sim A(\pi)$  se střední hodnotou  $E(Y) = \pi$ , je obor hodnot omezen na hodnoty od nuly do jedné tak, že jev  $Y = 1$  nastane s pravděpodobností  $\pi$  a jev  $Y = 0$  nastane s pravděpodobností  $(1 - \pi)$ . Pravděpodobnost nastoupení těchto jevů je dáno intervalem  $\langle 0, 1 \rangle$ . Pracujeme proto s poměrem pravděpodobnosti „vzniku“ jevu k pravděpodobnosti „nevzniku“ jevu  $\frac{\pi}{1 - \pi}$ , který označujeme jako šance (odds). Ten může, jak již bylo zmíněno, nabývat jakékoli nezáporné hodnoty.

Je-li v zobecněném lineárním modelu místo podmíněné střední hodnoty použit logaritmus šance logit, viz (3.9), dojdeme k binárnímu logistickému regresnímu modelu, ve kterém je logit vyjádřen jako lineární funkce vysvětlujících proměnných.

Šanci neboli odds můžeme upravit takto

$$\frac{\pi}{1 - \pi} = e^{x' \beta} \quad (3.10)$$

a dále jako pravděpodobnost


$$\pi = \frac{e^{x'\beta}}{1 + e^{x'\beta}}, \quad (3.11)$$

což je distribuční funkce logistického rozdělení. Pokud máme pouze jednu vysvětlující veličinu, pak má distribuční funkce tvar

$$F(x) = \frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}}. \quad (3.12)$$

Grafem této nelineární funkce pro  $\beta_1 > 0$  je symetrická rostoucí *s*-křivka s jedním inflexním bodem. Hodnota veličiny  $\beta_0 + \beta_1 x$  (a tedy logit) je  $100\%\pi$  kvantilem normovaného logistického rozdělení. V případě, že  $\beta_1 < 0$ , pak je *s*-křivka klesající a nejde tak již o graf distribuční funkce. Podobnou distribuční funkci se stejným inflexním bodem má i normované normální rozdělení, kde se jeho  $100\%\pi$  kvantil označuje jako probit. Normované normální a normované logistické rozdělení jsou obě symetrická s nulovou střední hodnotou, liší se však variabilitou a koncentrací. Při odhadu střední hodnoty vysvětlované veličiny pomocí obou rozdělení je dosahováno podobných hodnot, přesto jsou logitové modely upřednostňovány a to z důvodu snazší interpretace. Více se této problematice věnuje Hebák (2007).

Obr. 3.1: Symetrická *s*-křivka



Zdroj: <http://upload.wikimedia.org>

Absolutní člen  $\beta_0$  udává velikost logitu v případě, že další vysvětlující proměnné jsou nulové a je tedy logaritmem šance, že  $Y = 1$ . Je-li  $\beta_0 = 0$ , pak tato šance je  $\pi = 0,5$ , tedy šance jedna k jedné. Kladné hodnoty parametru znamenají větší šanci vzniku

sledovaného jevu ( $\pi > 0,5$ ) a záporné hodnoty znamenají větší šanci vzniku jevu alternativního. Logaritmus šance se mění se změnou počtu vysvětlujících proměnných, velikost je rovna  $e^{\beta_j}$  násobku šance při změně nezávislé veličiny o jedničku za předpokladu nezměněných hodnot ostatních veličin.

### 3.4.2. Vysvětlující proměnné

V logistickém regresním modelu se můžeme stejně jako u lineárního modelu setkat s kategoriálními, tak s kvantitativními proměnnými. Právě povaha vstupních hodnot je důležitá a rozhodující při konstrukci modelu, odhadu jeho parametrů, hodnocení kvality modelu i jeho využití. Důležitým předpokladem u vysvětlujících proměnných je, aby jejich jednotlivé kombinace byly jedinečné a neopakovaly se. U spojitých vstupních dat tento problém nenastává, složitější je to u dat kategoriálních. V tomto případě musíme data roztrždit do vícerozměrné kontingenční tabulky a použít logistické modelování četností získané tříděním. Četnosti výskytu kombinací, pro něž  $Y = 1$ , mají binomické rozdělení s pravděpodobností funkcí

$$P(y | n, \pi) = \binom{n}{y} \pi^y (1 - \pi)^{n-y}, \quad (3.13)$$

kde  $y$  je počet případů, kdy vysvětlovaná veličina  $Y = 1$  a  $n$  je celkový počet případů pro jednu konkrétní kombinaci hodnot vysvětlujících proměnných. Vysvětlovanou veličinou je pak relativní četnost nastoupení sledovaného jevu pro určitou kombinaci vysvětlujících veličin neboli  $p = \frac{y}{n}$ .

### 3.4.3. Odhad koeficientů

Podle charakteru vysvětlujících proměnných se při odhadu parametrů logistické regresní funkce vychází buď z netříděné datové matice, pokud jsou vysvětlující veličiny kvantitativní spojité (postačuje alespoň jedna spojitá veličina), nebo z relativních četností nastoupení sledovaného jevu pro určitou kombinaci hodnot vysvětlujících proměnných zjištěných po rozdělení do kontingenční tabulky, pokud je nezávisle proměnná kategoriální.



K odhadu parametrů lineární regresní funkce se využívá metoda nejmenších čtverců. V případě logistické regresní funkce se však kvůli dichotomické vysvětlované proměnné používá k odhadu metoda maximální věrohodnosti.

Metoda maximální věrohodnosti je metodou pro získání maximálně věrohodných odhadů parametrů regresní funkce pro různé typy rozdělení. Základem metody je maximalizace věrohodnostní funkce, která se liší právě daným typem rozdělení. Následně se určuje logaritmus této funkce, stanoví se parciální derivace logaritmu funkce, anulováním se získá soustava věrohodnostních rovnic, ze kterých se po vyřešení získají maximálně věrohodné odhady neznámých parametrů, více viz Hebák (2004).

V případě logistické regrese s binomickou vysvětlovanou proměnnou a spojitými vysvětlujícími veličinami jsou jednotlivá pozorování nezávislá a věrohodnostní funkci můžeme zapsat jako součin pravděpodobností jednotlivých pozorování, viz Hosmer a Lemeshow (2000),

$$L(\hat{\beta}) = \prod_{i=1}^n \pi_i^{y_i} (1 - \pi_i)^{1-y_i} . \quad (3.14)$$

Dosadíme-li do rovnice (3.14) již odvozený vzorec pro logistickou regresi (3.11) a následně jej upravíme, získáme následující tvar věrohodnostní funkce

$$L(\hat{\beta}) = \prod_{i=1}^n \frac{(e^{x_i' \beta})^{y_i}}{1 + e^{x_i' \beta}} . \quad (3.15)$$

Abychom našli parametry, pro které věrohodnostní funkce nabývá svého maxima, zlogaritmujeme tuto funkci. Pracujeme-li přitom pouze s jedinou vysvětlující proměnnou, má lineární kombinace vysvětlujících proměnných tvar  $\beta_0 + \beta_1 x_i$  a logaritmus věrohodnostní funkce vypadá takto

$$\ln L(\hat{\beta}) = \sum_{i=1}^n y_i (\beta_0 + \beta_1 x_i) + \sum_{i=1}^n \ln(1 + e^{\beta_0 + \beta_1 x_i}) . \quad (3.16)$$

Po anulování první derivace dle jednotlivých parametrů, získáme soustavu nelineárních rovnic

$$\sum_{i=1}^n y_i + \sum_{i=1}^n \frac{e^{\beta_0 + \beta_1 x_i}}{1 + e^{\beta_0 + \beta_1 x_i}} = 0,$$

$$\sum_{i=1}^n y_i x_i + \sum_{i=1}^n \frac{x_i e^{\beta_0 + \beta_1 x_i}}{1 + e^{\beta_0 + \beta_1 x_i}} = 0.$$
(3.17)

Soustava věrohodnostních rovnic je však nelineární v parametrech a vyžaduje speciální metody k vyřešení. K odhadu parametrů je potřeba zvolit některý z iteračních postupů, např. Newtonovu-Raphsonovu metodu. Princip metody spočívá v maximalizaci aproximace logaritmu věrohodnostní funkce v okolí počátečního odhadu pomocí prvních tří členů Taylorova rozvoje, viz Pecáková (2007). V každém iteračním kroku je navíc spočtena kovarianční matice odhadu parametrů, jejíž prvky z hlavní diagonály (rozptyly) je možno použít při konstrukci směrodatných chyb bodových odhadů i intervalů spolehlivosti.

Vzorec pro bodový odhad logitu s jednou vysvětlující proměnnou, který vychází z maximálně věrohodných bodových odhadů parametrů, je dán následovně

$$\hat{g}(x) = \ln\left(\frac{\hat{\pi}}{1 - \hat{\pi}}\right) = \hat{\beta}_0 + \hat{\beta}_1 x_1,$$
(3.18)

kde veličiny se stříškou znamenají odhad.

#### 3.4.4. Testování významnosti koeficientů

Dalším krokem po odhadu parametrů je testování vhodnosti zvolených koeficientů. Zvolené koeficienty totiž nemusí být vždy vhodné k predikci vysvětlované proměnné. Pro testování, zda je vliv vysvětlující proměnné na vysvětlovanou veličinu statisticky významný, můžeme použít test založený na Waldově statistice. Test porovnává odhadnutou hodnotu parametru a jeho směrodatnou odchylku

$$W_j = \frac{\hat{\beta}_j}{\hat{s}(\hat{\beta}_j)},$$
(3.19)

kde  $\hat{\beta}_j$  značí odhadnutou hodnotu parametru a  $\hat{s}(\hat{\beta}_j)$  je směrodatná odchylka odhadnutého parametru.

Waldova statistika má asymptoticky normované normální rozdělení a slouží jako testové kritérium pro ověření hypotézy, že parametr  $\beta_j$  nabude hodnoty nula. Jde o alternativu individuálního  $t$ -testu v lineární regresi. Test je vhodný pro prvotní nástřel, zda je parametr statisticky významný, má však své omezení, proto je vhodné doplnit tento test i jinými.

Jiný způsob testování významnosti koeficientů uvádí Hosmer a Lemeshow (2000). Jejich požadavkem je, aby model obsahující danou proměnnou, poskytoval o vysvětlované veličině více informací než model, který tuto proměnnou neobsahuje. Kvalita modelu je posuzována na základě porovnání napozorovaných hodnot závisle proměnné s jejími teoretickými hodnotami vypočtenými modelem.

V případě lineární regrese se posuzují vzdálenosti mezi napozorovanými daty a empirickými daty pomocí reziduálního součtu čtverců, které se stanoví jak pro model, který testovanou veličinu obsahuje, tak pro model, který veličinu nezahrnuje. Přidáním další veličiny do modelu dojde vždy k poklesu reziduálního součtu čtverců, proto je předmětem zájmu velikost této změny, která vypovídá o statistické významnosti proměnné.

V logistické regresi nás omezuje fakt, že model není lineární v parametrech, proto přistupujeme k testu, který kvalitu modelu posuzuje na základě poměru dvou věrohodnostních funkcí (3.17) na základě zjištěných a vypočítaných hodnot, tzv. test věrohodnostním poměrem. Vzorec má následující tvar

$$D = -2 \ln \left[ \frac{\prod_{i=1}^n \hat{\pi}_i^{y_i} (1 - \hat{\pi}_i)^{1-y_i}}{\prod_{i=1}^n \pi_i^{y_i} (1 - \pi_i)^{1-y_i}} \right], \quad (3.20)$$

který následně zjednodušíme

$$D = -2 \sum_{i=1}^n \left[ y_i \ln \left( \frac{\hat{\pi}_i}{\pi_i} \right) + (1 - y_i) \ln \left( \frac{1 - \hat{\pi}_i}{1 - \pi_i} \right) \right], \quad (3.21)$$

kde  $D$  je *deviance* a v logistické regresi má stejnou vypovídací schopnost jako reziduální součet čtverců v případě lineární regrese. O statistické významnosti testované proměnné je pak rozhodnuto na základě statistické významnosti rozdílu deviancí dvou

modelů, z nichž jeden obsahuje a druhý neobsahuje testovanou veličinu. Zapsat to můžeme takto

$$G = D(\text{model bez proměnné } X_j) - D(\text{model s proměnnou } X_j). \quad (3.22)$$

Máme-li dva různé modely s počtem parametrů  $p_1$  a  $p_0$ , přičemž  $p_1 > p_0$  (stále pracujeme pro zjednodušení s jedinou vysvětlující veličinou, tedy  $p_1 = 2$ ), získáme po dosazení vztahu (3.21) do rovnice (3.22) testové kritérium  $G$  dané vztahem

$$G = -2 \ln \left[ \frac{\left( \frac{n_1}{n} \right)^{n_1} \left( \frac{n_0}{n} \right)^{n_0}}{\prod_{i=1}^n \pi_i^{y_i} (1 - \pi_i)^{1-y_i}} \right], \quad (3.23)$$

kde čítec vzorce vyjadřuje věrohodnostní funkci modelu bez testované veličiny, přičemž  $n_1 = \sum y_i$  a  $n_0 = \sum (1 - y_i)$ , které má rozdělení  $\chi^2$  s  $p_1 - p_0 = 1$  stupni volnosti, viz Hosmer a Lemeshow (2000). Porovnáním vypočtené hodnoty se následně rozhodneme o statisticky významném vlivu sledované veličiny na vysvětlovanou proměnnou. Tato statistika je obdobou sekvenčního  $F$ -testu v lineární regresi.

Základem Waldova testu i testu věrohodnostním poměrem je výpočet maximálně věrohodného odhadu parametru  $\hat{\beta}_1$ . Ten lze nahradit použitím tzv. *Score* testu. Matematický zápis *Score* testu je takovýto

$$ST = \frac{\sum_{i=1}^n x_i (y_i - \bar{y})}{\sqrt{\bar{y}(1 - \bar{y}) \sum_{i=1}^n (x_i - \bar{x})^2}}, \quad (3.24)$$

kde čítec představuje výpočet maximálně věrohodného odhadu parametru  $\hat{\beta}_0$ , při užití vztahu  $\hat{\pi} = \frac{n_1}{n} = \bar{y}$ , a jmenovatel je roven vzorci pro odhad rozptylu tohoto parametru.

*Score* test má  $\chi^2$  rozdělení a porovnáním příslušného kvantilu s vypočtenou hodnotou  $ST$  můžeme rovněž rozhodnout o statistické významnosti vlivu testované veličiny.

### 3.4.5. Stavba modelu

Predikční model pomocí logistické regrese vytváříme postupně. Dle Hosmer a Lemeshow (2000) je vhodné začít jednorozměrnou analýzou, což znamená otestovat každou vysvětlující proměnnou vůči vysvětlované veličině zvlášť. Máme-li jedinou spojitou vysvětlující proměnnou, je k otestování statistické významnosti veličiny vhodný již výše uvedený Waldův test. V případě, že vysvětlující veličiny jsou nominální, ordinální, či spojitě proměnné s malým počtem hodnot, využívá se k tomuto otestování kontingenční tabulka. K ověření shody kvality těsnosti daných a nalezených četností se využívá Pearsonův  $\chi^2$  test dobré shody s  $k - 1$  stupni volnosti, jenž je asymptoticky shodný s  $\chi^2$  testem věrohodnostním poměrem.

Po prvotní selekci staticky nevýznamných vysvětlujících veličin přecházíme k hledání modelu s více proměnnými. Používá se k tomu metoda postupné regrese, neboli stepwise regression. Princip metody spočívá v testování významnosti nezávislých veličin po přidání další veličiny do modelu. Jednotlivé proměnné se totiž mohou vzájemně ovlivňovat, jsou mezi nimi interakce, což může mít za následek statistickou nevýznamnost některé z předchozích zahrnutých veličin po přidání nové proměnné do modelu. Hodnocení neprobíhá na tradiční hladině významnosti 5% (tzv.  $p$ -hodnota), ale na hladině 25% a to z důvodu, aby nedošlo opomenutí některé z významnějších proměnných. Konečné rozhodnutí o zařazení některého z parametrů do modelu má však analytik, který model vytváří, neboť z věcného hlediska může mít zahrnutí dané veličiny podstatný význam k popsání zkoumané problematiky.

Stepwise regression metoda má dvě podoby a to dle toho, zda jsou veličiny do modelu postupně zařazovány – forward stepwise, nebo jsou-li z modelu postupně vyřazovány – backward elimination. Metoda postupné regrese se v hojné míře používá především v lineární regresi, kde vychází ze zkoumání přírůstků regresního součtu čtverců pomocí sekvenčních  $F$ -testů nebo ze zvýšení indexu determinace.

### 3.4.6. Hodnocení výsledného modelu

Pro hodnocení kvality každého modelu, v našem případě regresního, je vždy rozhodujícím kritériem cíl analýzy, a tím i použitelnost výsledků. Správný regresní model by měl co nejlépe vyhovovat nejen vybraným datům, ale také populaci, z níž výběr pochází. Logistický regresní model můžeme hodnotit podle toho, nakolik je


schopen na základě vysvětlujících veličin rozlišovat, u kterých jednotek sledovaný jev nastane a u kterých nikoli, nebo jej můžeme hodnotit podle toho, nakolik se pro určité kombinace hodnot nezávislých veličin shodují zjištěné a očekávané četnosti nastoupení zkoumaného jevu, viz Hebák (2007).

Nástrojů pro hodnocení kvality výsledného modelu je celá řada, zmiňme dvě základní metody, tedy čtyřpolní klasifikační tabulku a křivku *ROC*.

Čtyřpolní klasifikační tabulka se používá pro znázornění schopnosti regresního modelu správně klasifikovat jednotky podle hodnoty  $Y$ . Tabulka obsahuje četnosti správně a mylně zařazených jednotek. Úspěšnost modelu se následně posuzuje podle podílu správně klasifikovaných jednotek (nalezneme je na hlavní diagonále tabulky) k celkovému počtu klasifikovaných jednotek, neboli  $(n_{11} + n_{22}) / n$ .


Druhou zmiňovanou metodou k hodnocení diskriminační schopnosti modelu je křivka *ROC* (Receiver Operating Characteristic Curve). Základem této grafické metody je jednotkový čtverec, jehož svislá osa představuje tzv. senzitivitu a vodorovná osa značí tzv. 100 – specifická. Senzitivita vyjadřuje procento případů, které byly správně označeny vzhledem ke zkoumanému jevu. Vodorovná osa zaznamenává procento případů, kdy došlo ke špatné klasifikaci jednotek vzhledem ke zkoumanému jevu. Křivka *ROC* pak představuje kombinaci hodnot senzitivity a specifity. Nastat mohou dvě extrémní situace, první je, když křivka *ROC* má tvar diagonály. V takovémto případě model postrádá jakoukoli diskriminační schopnost a není tak vhodný pro predikci. V druhém extrémním případě splývá křivka s levým horním rohem, což znamená absolutní shodu skutečných a predikovaných hodnot. Model se tak stává stoprocentně úspěšným a vhodným k predikci.

Obr. 3.2: Vztah senzitivity a specificity



Zdroj: <http://www.medcalc.org>

Obr. 3.3: Křivka ROC



Zdroj: <http://www.medcalc.org>

S křivkou *ROC* přímo souvisí i ukazatel *AUC* (Area Under ROC Curve) neboli plocha pod křivkou *ROC*. Ukazatel je vhodný k porovnání dvou či více *ROC* křivek, které převádí na jednu skalární veličinu umožňující jejich komparaci. Ukazatel *AUC* může nabýt hodnot od 0,5 do 1, přičemž vyšší hodnota znamená přesnější predikční model.

K hodnocení logistického regresního modelu se dále užívají metody založené na modifikaci testu věrohodnostním poměrem, které již zohledňují počet vysvětlujících proměnných. Jde například o Akaikeho informační kritérium, Goodmanův index, či Bayesovské kritérium, viz Pecáková (2007).

### 3.5. Vybrané predikční modely

V úvodu třetí kapitoly bylo zmíněno, že ve finanční oblasti se predikční modely věnují především predikci bonity klienta nebo predikci finanční tísně. Z tohoto pohledu rozlišujeme modely bonitní a bankrotní. Modely vycházejí z předpokladu, že budoucí negativní vývoj finanční situace podniku lze již dříve rozpoznat z určitých příznaků. Společné oběma typům modelů je rovněž snaha o vyjádření finančního zdraví podniku jediným koeficientem, ale i metody, které se při tvorbě modelů používají. Jde například o lineární a nelineární regresi, modely diskrétní volby, diskriminační analýzu, expertní systémy, fuzzy modely a neuronové sítě, viz Dluhošová (2010).

#### 3.5.1. Bonitní modely

Bonitní neboli diagnostické modely by měly zodpovědět otázku, o jakou společnost se jedná, zda je „zdravá“, či nikoli. Na rozdíl od bankrotních modelů, které hodnotí možnost úpadku podniku, bonitní modely vyjadřují bonitu společnosti, nebo také možnost zhoršení finanční situace.

Mezi bonitní modely řadíme zejména Tamariho model, Kralickův Quick-test, Index bonity a Grünwaldův index bonity. Princip výpočtu těchto modelů je obdobný. U Tamariho modelu, Kralickova Quick-testu a Grünwaldova indexu bonity se vypočtou vybrané ukazatele z finanční analýzy a dle jejich hodnot se jim přiřadí body, které po sečtení a porovnání s výslednou klasifikační tabulkou určí bonitu společnosti. Index bonity rovněž počítá s vybranými finančními ukazateli, kterým následně určí váhu. Získá se tak jedno jediné číslo, které dle klasifikační tabulky opět určí, o jakou firmu se jedná. Pro názornost uveďme z výše zmíněných alespoň Index bonity.

#### *Index bonity*

Index bonity je založen na multivariační diskriminační analýze podle zjednodušené metody, viz Sedláček (2007). Hodnocení bonity podniku podle tohoto indexu bývá často využíváno v německy mluvících zemích.

Model zahrnuje šest následujících ukazatelů

$$x_1 = \text{cash flow} / \text{cizí zdroje}, \quad (3.25)$$

$$x_2 = \text{aktiva} / \text{cizí zdroje}, \quad (3.26)$$



$$x_3 = EBT / \text{aktiva}, \quad (3.27)$$

$$x_4 = EBT / \text{výkony}, \quad (3.28)$$

$$x_5 = \text{zásoby} / \text{výkony}, \quad (3.29)$$

$$x_6 = \text{výkony} / \text{aktiva}. \quad (3.30)$$

Index bonity ( $B_i$ ) se pak vypočte po dosazení získaných hodnot do této rovnice

$$B_i = 1,5x_1 + 0,08x_2 + 10x_3 + 5x_4 + 0,3x_5 + 0,1x_6. \quad (3.31)$$

Výsledek rovnice (3.31) je kritériem hodnocení Indexu bonity. Pro společnost je nejlepší co největší hodnota  $B_i$ , jak je patrné z následující Tab. 3.1.

Tab. 3.1: Hodnocení dle Indexu bonity

$B_i = 3$ a více	extrémně dobrá firma
2 až 3	velmi dobrá firma
1 až 2	dobrá firma
0 až 1	firma s určitými problémy
-1 až 0	špatná firma
-2 až -1	velmi špatná firma
-3 až -2	extrémně špatná firma

Zdroj: Sedláček (2007)

### 3.5.2. Bankrotní modely

Účel bankrotních modelů je již z názvu patrný. Mají předvídat, zda se společnost v blízké budoucnosti dostane do existenčních potíží. Předpokládá se, že za krachem společnosti stojí celá řada špatných rozhodnutí a série chybných postupů managementu firmy. Finanční těžkosti je možné rozpoznat ještě před tím, než skutečně nastanou a umožní tak věřitelům, investorům podstoupit „ozdravné“ kroky vedoucí k záchraně firmy.

K bankrotním modelům řadíme Beaverův model, Altmanovu formuli bankrotu, Taflerův model a Index IN. Princip výpočtu těchto modelů je opět obdobný, vypočtou se vybrané finanční ukazatele z oblasti rentability, likvidity, zadluženosti a aktivity, následně se jim dle významnosti přiřadí váhy (u Indexu IN se váhy liší podle odvětví). Po dosazení do diskriminační funkce získáme číslo, které na základě klasifikační tabulky prozradí, zda firmě hrozí v budoucnu existenční problémy. Jako zástupce bankrotních modelů uvedme asi nejznámější Altmanův model.

### *Altmanova formule bankrotu (Z-skóre)*

Profesor financí E. I. Altman aplikoval v roce 1968 přímou statistickou metodu tzv. násobnou diskriminační analýzu, aby zjistil, jakou váhu mají jednotlivé poměrové ukazatele. Ty byly následně zahrnuty do modelu jako proměnné. Váhy jednotlivých ukazatelů i výběr ukazatelů se opírá o zosobnění výsledků velmi rozsáhlého empirického průzkumu uskutečněného v USA někdy koncem 60. a během 80. let. Analýza byla provedena na několika společnostech, a to rovnoměrně rozdělených na bankrotující a nebankrotující. Výsledkem je Altmanova diskriminační funkce vedoucí k sestavení Z-skóre diferencovaně pro firmy s akciemi veřejně obchodovatelnými na burze a zvláště pro předvídaní finančního vývoje ostatních firem. Z počátku Altman do svého modelu zahrnul 22 finančních poměrových ukazatelů, které následně zredukoval na pět nejdůležitějších, jimiž jsou

$$A = \text{čistý provozní kapitál/aktiva}, \quad (3.32)$$

$$B = \text{nerozdělený zisk/aktiva}, \quad (3.33)$$

$$C = \text{zisk před daní a úroky/aktiva}, \quad (3.34)$$

$$D = \text{tržní hodnota vlastního kapitálu/účetní hodnota celkových dluhů}, \quad (3.35)$$

$$E = \text{celkový obrát/aktiva}. \quad (3.36)$$

U firem, jejichž akcie nejsou veřejně obchodované na kapitálovém trhu, se ukazatel  $D$  vypočte jako podíl vlastního kapitálu v účetní hodnotě k celkovým dluhům.

Hodnoty získané z jednotlivých ukazatelů se dosadí buď do rovnice pro firmy s veřejně obchodovatelnými akciemi

$$Z = 1,2A + 1,4B + 3,3C + 0,6D + E, \quad (3.37)$$

nebo do rovnice pro firmy, jejichž akcie nejsou veřejně obchodované na kapitálovém trhu

$$Z = 0,717A + 0,847B + 3,107C + 0,42D + 0,998E. \quad (3.38)$$

Dosáhne-li společnost s veřejně obchodovatelnými akciemi hodnoty  $Z$  větší než 2,99, její finanční situace je považována za uspokojivou. Pohybuje-li se hodnota  $Z$  mezi 1,81 až 2,99, jedná se o tzv. „šedou zónu“ nevyhraněných výsledků. Vážnými finančními problémy je ohrožena společnost, jejíž hodnota  $Z$  je menší než 1,81.

U ostatních společností jsou hodnoty ukazatele  $Z$  upraveny. Hodnota  $Z$  větší než 2,9 značí uspokojivou finanční situaci podniku, hodnota  $Z$  v rozmezí 1,2 až 2,9 představuje „šedou zónu“ nevyhraněných výsledků a  $Z$  menší než 1,2 upozorňuje na vážné ohrožení finančního zdraví podniku.

Altmanovo  $Z$ -skóre bylo vytvořeno pro společnosti na relativně efektivním americkém trhu, ve kterém se vyskytuje velké množství konkurzů, avšak situace v České republice je v tomto smyslu velmi odlišná. Jiná je nejenom legislativa v oblasti konkurzního práva a ochota příslušných soudů vyhlásit na předluženou společnost konkurz, ale i celkové „měkkí“ ekonomické prostředí, které umožňuje společností existovat při takovém vývoji ukazatelů, který by např. v americkém prostředí vedl nevyhnutelně ke konkurzu. Z tohoto důvodu autoři ekonomických knih varují před používáním Altmanova  $Z$ -skóre při hodnocení finančního zdraví českých podniků.

#### **4. STANOVENÍ PREDIKČNÍHO MODELU ÚPADKU**

Čtvrtá kapitola diplomové práce představuje část aplikační. Jejím cílem je vytvoření predikčního modelu úpadku firem metodou logistické regrese pomocí statistického programu STATA.

Základem pro vytvoření jakéhokoli modelu jsou správná data. V tomto případě to jsou data finanční, přesněji finanční výkazy firem. Z databáze MagnusWeb od společnosti ČEKIA byly staženy finanční výkazy 400 firem (pouze společnosti s ručením omezeným a akciové společnosti, případně bytová družstva) za hospodářský rok 2008. Z tohoto počtu bylo 200 prosperujících firem, které ke konci roku 2009 neměly finanční problémy, druhou polovinu tvořily firmy, které se během roku 2009 ocitly ve finanční tísní. Za finanční tíseň bylo považováno např. prohlášení konkursu, zahájení insolventního řízení, prohlášení úpadku podniku apod.

##### **4.1. Finanční analýza firem**

Dalším neméně významným krokem bylo provedení finanční analýzy pro obě skupiny firem. Bylo vybráno 20 poměrových ukazatelů finanční analýzy: rentabilita vlastního kapitálu ROE, rentabilita aktiv ROA (spočtena pomocí EBITDA), rentabilita aktiv ROA (spočtena pomocí EBITu), rentabilita tržeb ROS, celková zadluženost, běžná zadluženost, úvěry/pasiva, úrokové zatížení, stupeň krytí stálých aktiv, zadluženost vlastního kapitálu, úvěrová zadluženost, doba obratu zásob, doba obratu pohledávek, doba obratu závazků, běžná likvidita, pohotová likvidita, okamžitá likvidita, poměrový ukazatel likvidity, přidaná hodnota/tržby a finanční páka.

První závažný problém při výpočtu nastal u ukazatele ROE. Rentabilita vlastního kapitálu poměřuje čistý zisk firmy s jeho vlastním kapitálem, který však u mnoha firem vycházel záporně z důvodu nakumulování dlouhodobých ztrát. Právě nesmyslné hodnoty vedly k vyloučení ukazatele ROE z finanční analýzy.

Během analýzy bylo zjištěno, že mnohé z bankrotujících firem nevykazují vůbec žádné tržby, což při výpočtu některých ukazatelů, u kterých jsou tržby ve jmenovateli, způsobovalo nemalé problémy. Bylo proto rozhodnuto těchto konkrétně 28 firem vynechat a s jejich údaji dále nepočítat.

## 4.2. Jednorozměrná analýza

Při tvorbě predikčního modelu úpadku byla provedena jednorozměrná analýza, která měla určit, které z ukazatelů jsou pro predikci bankrotu statisticky významné. Jednorozměrná analýza v programu STATA pracuje s předpokladem, že ostatní vysvětlující veličiny jsou nulové. V následující Tab. 4.1 jsou uvedeny hodnoty pro analýzu vlivů jednotlivých vysvětlujících veličin na bankrot firmy. Tabulka je zkrácená, originál tabulky programu STATA pro všech 19 ukazatelů jsou uvedeny v Příloze č.1.

Tab. 4.1: Statistická významnost vlivu daného ukazatele na bankrot firmy

Logistic regression		
Vysvětlovaná veličina	Bankrot	$P >  z $
Vysvětlující veličiny	ROA (EBITDA)	0,000
	ROA	0,000
	ROS	0,003
	Celková zadluženost	0,000
	Úvěry/pasiva	0,000
	Doba obratu zásob	0,093
	Doba obratu pohledávek	0,221
	Doba obratu závazků	0,267
	Běžná likvidita	0,000
	Pohotovlá likvidita	0,000
	Okamžitá likvidita	0,000
	Poměrový ukazatel likvidity	0,004
	Přidaná hodnota/tržby	0,000
	Finanční páka	0,946
	Úrokové zatížení	0,166
	Stupeň krytí stálých aktiv	0,017
	Běžná zadluženost	0,000
	Zadluženost vlastního kapitálu	0,952
	Úvěrová zadluženost	0,501

Zdroj: Vlastní zpracování

V Tab. 4.1 jsou zobrazeny hodnoty tzv. z-statistiky, jejíž hodnota musí být menší než 0,05, aby vliv zkoumané proměnné byl statisticky významný a veličina tak byla zařazena do modelu.

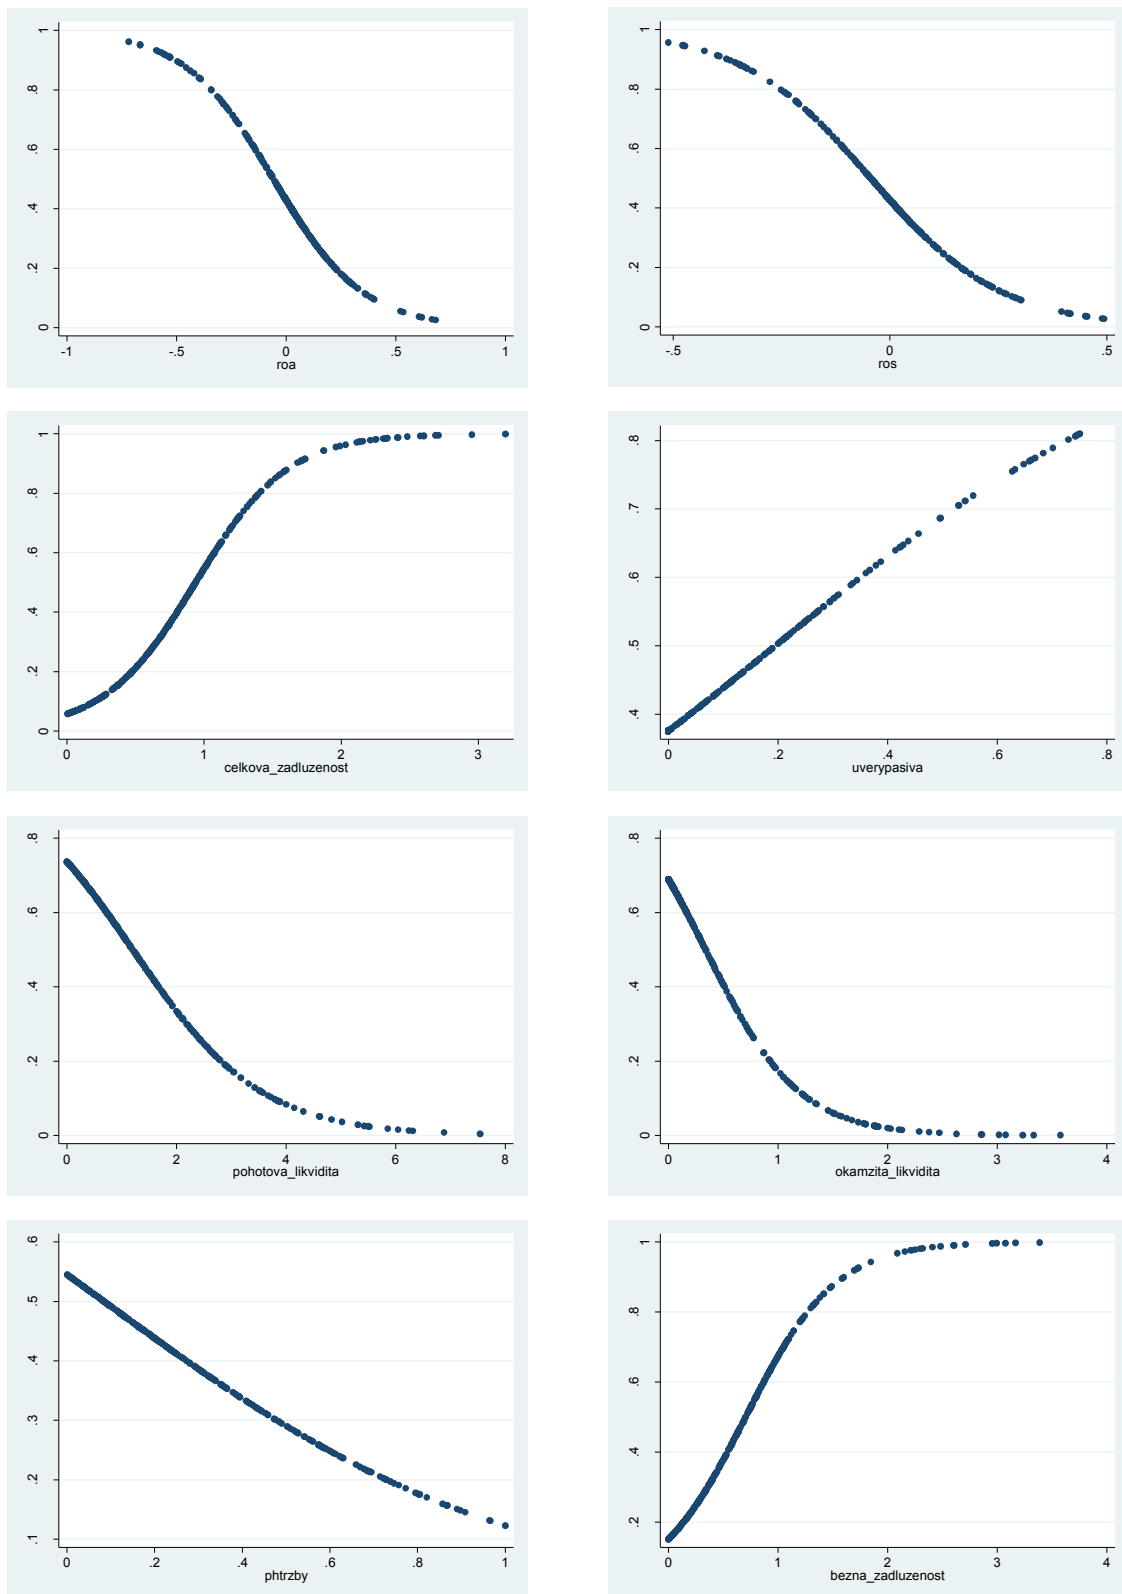
Po analyzování statistické významnosti vlivu jednotlivých veličin bylo vyloučeno celkem 11 ukazatelů. Jako nevhodné pro predikci byly určeny všechny tři ukazatele reprezentující oblast aktivity, čili doba obratu zásob, doba obratu pohledávek a doba obratu závazků. Dále to byl ukazatel finanční páky, úvěrové zadluženosti,

úrokového zatížení a ukazatel zadluženosti vlastního kapitálu. Vyřazen byl rovněž ukazatel ROA, který vycházel z nezdáněného zisku před úroky navýšeného o odpisy, přestože byl statisticky významný. Důvodem vyřazení byl obdobný princip výpočtu s ukazatelem ROA, který vychází rovněž z EBITu bez odpisů. Pro vytvoření vhodného modelu by dva velmi podobné ukazatele byly zbytečné. Vyloučen byl ukazatel běžné likvidity a poměrový ukazatel likvidity, neboť oblast likvidity dostatečně reprezentují zbylé dva ukazatele – okamžitá a pohotová likvidita. Ukazatel stupně krytí stálých aktiv byl rovněž vypuštěn a to z důvodu, že v daném vzorku firem bylo hned několik desítek společností, které neměly vůbec stálá aktiva.

Dalším krokem u zbylých osmi ukazatelů bylo odstranění extrémně odlehlých a nesmyslných hodnot. Ve vzorku 372 firem se objevovaly velmi extrémní hodnoty, které neodpovídaly realitě a v konečném důsledku by zkreslovaly vypovídací schopnost výsledného predikčního modelu. Extrémně odlehlé hodnoty nalezneme, když od dolního kvantilu ( $x_{0,25}$ ) odečteme trojnásobek rozdílu třetího a prvního kvantilu, respektive ke třetímu kvantilu ( $x_{0,75}$ ) přičteme trojnásobek rozdílu třetího a prvního kvantilu. Za touto hranicí lze hodnoty považovat za extrémně odlehlé. S nesmyslnými hodnotami typu záporná zadluženost apod. se rovněž v modelu nepracovalo. Vyskytla-li se ve finanční analýze při výpočtu konkrétního ukazatele nesmyslná hodnota, byla firma v daném případě vypuštěna ze vzorku. Předmětem zájmu tedy byly pouze reálné hodnoty a hodnoty, které nebyly extrémní.

Pro znázornění pravděpodobnosti vzniku bankrotu v závislosti na dané nezávislé proměnné byly v programu STATA vytvořeny následující grafy.

Obr. 4.1: Pravděpodobnost vzniku bankrotu na hodnotě daného ukazatele



Zdroj: Vlastní zpracování v programu STATA

Z grafů jsou patrné různé pravděpodobnosti vzniku bankrotu v závislosti na daném ukazateli. Na základě prvního grafu lze konstatovat, že s rostoucí rentabilitou

aktiv dochází ke snížení pravděpodobnosti vzniku bankrotu. Pokud tvoří provozní zisk přibližně 50% aktiv, je pravděpodobnost finanční tísně téměř nulová. Takovéto rentability musí ovšem podnik dosahovat dlouhodobě.

Obdobnou křivku nalezneme i v grafu závislosti bankrotu na vývoji rentability tržeb. Se zvyšující se rentabilitou klesá pravděpodobnost problémů v hospodaření.

Opačně vyznívá graf závislosti vzniku finanční tísně v souvislosti s rostoucí celkovou zadlužeností. Pokud cizí kapitál přesáhne velikost celkových aktiv, jsou finanční problémy téměř zaručeny.

V dalším grafu je zaznamenána závislost vzniku finančních problémů vzhledem k rostoucímu poměru úvěrů k pasívům. Optimální hranice podílu úvěrů na pasivech by dle grafu mohla být do 20%.

Z grafu, který zaznamenává závislost vzniku bankrotu na výši pohotové likvidity, lze vyčíst, že se zvyšující se pohotovou likviditou pravděpodobnost bankrotu klesá. Obecně doporučovaná hranice od 1,5 do 2,5 se zdá být optimální.

Obecně doporučovanou hranicí u okamžité likvidity je hodnota 0,2. V tomto případě by to znamenalo ještě poměrně vysokou pravděpodobnost krachu společnosti (cca 55%), jak dokládá graf.

Z grafu závislosti vzniku bankrotu vzhledem k ukazateli PH/tržby je patrné, že s rostoucím podílem přidané hodnoty na tržbách klesá riziko bankrotu. V případě, že přidaná hodnota tvoří přibližně 30% tržeb, je riziko krachu nižší než 40%. Nutno poznamenat, že nesmí jít o výjimečnou záležitost, důležité je tento poměr stabilizovat.

S rostoucím poměrem krátkodobého kapitálu k aktivům rapidně roste riziko finanční tísně, jak je znázorněno v posledním z osmi grafů.

#### **4.3. Vícerozměrná analýza**

Po jednorozměrné analýze, která vyloučila 11 poměrových ukazatelů, a po zjištění vlivu nezávisle proměnné na hlavní vysvětlovanou veličinu, následovalo vytvoření modelu se všemi proměnnými metodou postupné regrese, neboli metodou stepwise regression. Hranice statistické významnosti ( $p$ -hodnota) byla zvolena na úrovni 25%, aby nedošlo k opomenutí některé z významnějších proměnných. Výsledky vícerozměrné analýzy jsou zachyceny v Tab. 4.2.



Tab. 4.2: Stepwise regression

p = <b>0.8166</b> >= 0.2500 removing <b>ros</b>						
p = <b>0.7549</b> >= 0.2500 removing <b>pohotova_likvidita</b>						
p = <b>0.4352</b> >= 0.2500 removing <b>celkova_zadluzenost</b>						
Logistic regression			Number of obs = 235			
			LR chi2(5) = 96.92			
			Prob > chi2 = 0.0000			
Log likelihood = -110.83698			Pseudo R2 = 0.3042			
bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
roa	-3.513848	1.268424	-2.77	0.006	-5.999913	-1.027782
bezna_zadl~t	1.959823	.526971	3.72	0.000	.9269784	2.992667
okamzita_l~a	-1.911067	.538656	-3.55	0.000	-2.966813	-.8553203
uverypasiva	3.24211	1.172034	2.77	0.006	.9449665	5.539254
phtrzby	1.716802	.8834028	1.94	0.052	-.0146356	3.44824
_cons	-1.537574	.5290971	-2.91	0.004	-2.574586	-.5005633

Zdroj: Vlastní zpracování v programu STATA

Z Tab. 4.2 je patrné, že po zahrnutí všech veličin do modelu se statisticky nevýznamným stal ukazatel rentability tržeb, ukazatel pohotové likvidity a ukazatel celkové zadluženosti. Mezi těmito třemi ukazateli a ostatními existovaly zřejmě interakce, které metoda stepwise odhalila. Interakce mezi veličinami lze rovněž modelovat, avšak pro svou náročnost není modelování interakcí předmětem této diplomové práce. K predikci úpadku firmy tedy postačuje zbylých pět poměrových ukazatelů. Zastoupena je tak oblast rentability, likvidity i zadluženosti.

#### 4.4. Ověření linearity logitu

Dalším krokem bylo zjištění, zda vliv jednotlivých veličin lze vyjádřit lineární funkcí. Tuto vlastnost je možno vyčíst z grafů nebo pomocí frakčního polynomu. Pomocí funkce `fracpoly` v programu STATA byly vytvořeny tabulky uvedené v Příloze č.2. Jejich zjednodušenou verzi představuje Tab. 4.3.

Tab. 4.3: Frakční polynomy

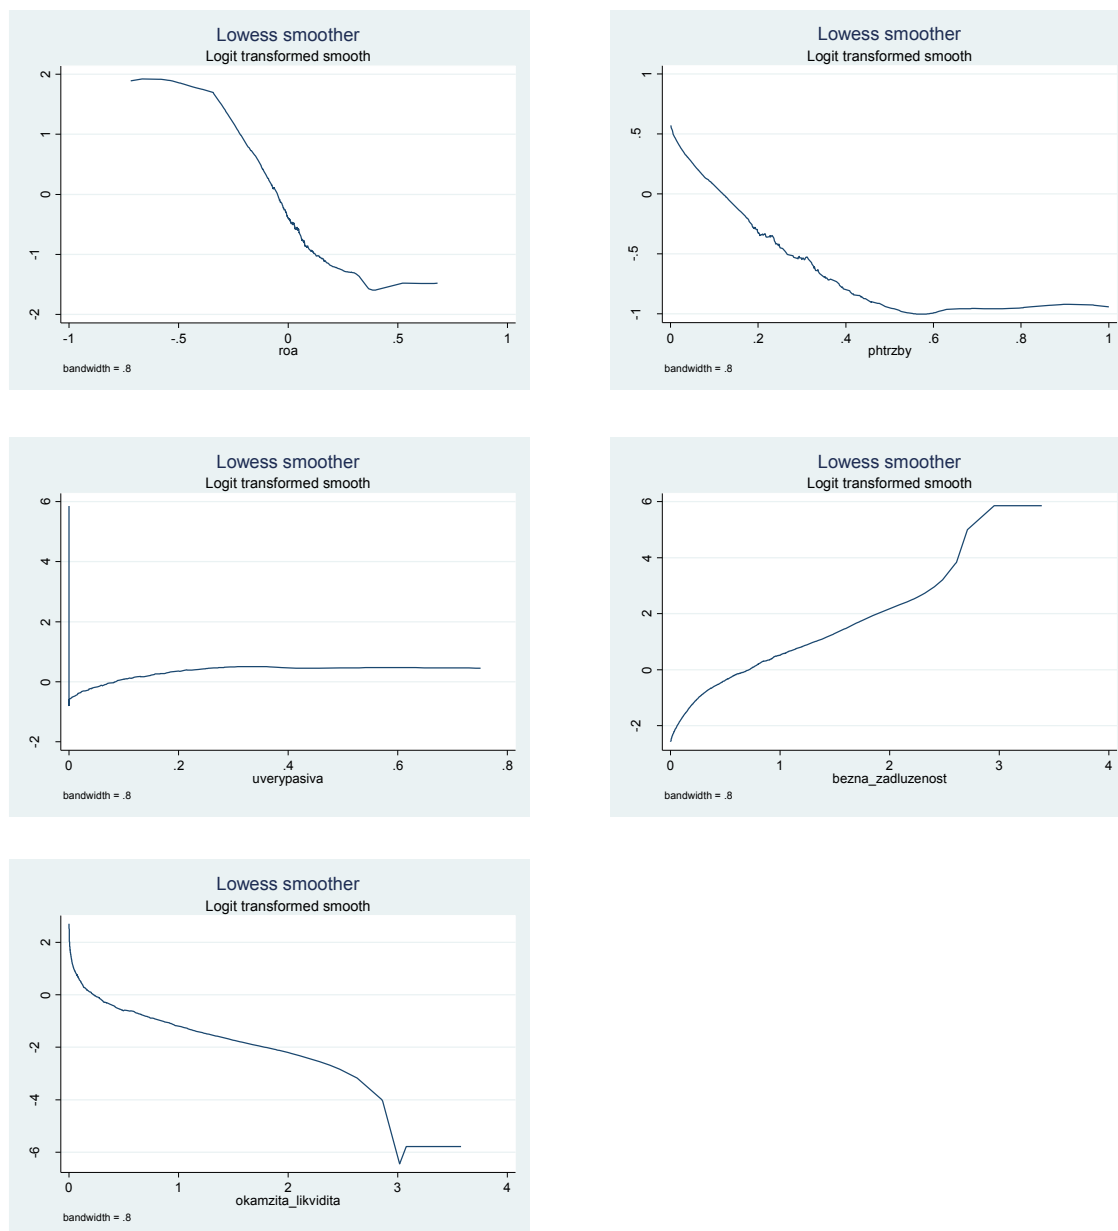
Vysvětlující veličina	P (*)		
	not in model	linear	m=1
ROA	0,000	0,055	0,022
PH/tržby	0,000	0,055	0,253
Úvěry/pasiva	0,000	0,006	0,690
Běžná zadluženost	0,000	0,127	0,338
Okamžitá likvidita	0,000	0,000	0,003

Zdroj: Vlastní zpracování

Aby se jednalo o lineární funkci logitu, viz (3.9), musí být hodnota  $P (*)$  u lineárního modelu vyšší než 0,05. Je-li nižší, nejde o lineární funkci a je třeba přejít k vytvoření kategorií u této proměnné. V případě rentability aktiv je hodnota  $P (*)$  na hranici, přesto budeme považovat funkci za lineární. U ukazatele PH/tržby vychází hodnota  $P (*)$  stejně jako u prvního ukazatele, budeme tedy předpokládat linearitu logitu. Vysvětlující veličinu úvěry/pasiva bude nutno na základě  $P (*)$  hodnoty převést na kategoriální.  $P (*)$  hodnota v případě ukazatele běžné zadluženosti svědčí o linearitě funkce. Veličinu tedy není třeba kategorizovat. I v případě posledního ukazatele dosahuje hodnota  $P (*)$  nižší hodnoty než 0,05 a nejde tedy o lineární funkci.

Zjistit linearitu logitu lze i graficky a to pomocí grafů lowess v programu STATA, které danou funkci vyhlazují. Grafy pro všech pět výše zmíněných nezávislých veličin jsou prezentovány Obr. 4.2.

Obr. 4.2: Grafické testování linearity logitů



Zdroj: Vlastní zpracování v programu STATA

Na Obr. 4.2 jsou znázorněny grafy, které vyjadřují závislost logitu na dané vysvětlující veličině. Jak již bylo zmíněno, v případě, že funkce logitu není lineární, je třeba přistoupit k převedení dané veličiny na kategoriální. Při posuzování linearity logitů pomocí grafů lowess však nebylo možné jednoznačně určit, kterou z funkcí lze ještě považovat za lineární a kterou nikoli. Subjektivně bychom mohli kteroukoli z křivek proložit přímkou. Proto bylo o linearitě, respektive nelinearitě logitů rozhodnuto podle frakčního polynomu, nikoli podle grafů lowess.

U dvou z pěti vysvětlujících proměnných bylo pomocí frakčního polynomu zjištěno, že jejich vliv na bankrot nelze vyjádřit jako lineární funkci a je třeba je převést

na veličiny kategoriální. Převedení ukazatelů úvěry/pasiva a okamžité likvidity bylo provedeno v aplikaci Excel a to pouze ze smysluplných hodnot a hodnot, které nebyly extrémně odlehlé. Použita byla funkce QUARTIL, která rozdělila jednotlivá pozorování dané veličiny na tři kvantily, jimž bylo následně přiřazeno kódování 0 pro hodnoty menší než  $x_{0,25}$ , 1 pro hodnoty menší než  $x_{0,5}$ , 2 pro hodnoty menší než  $x_{0,75}$ , 3 pro hodnoty větší než  $x_{0,75}$ .

V programu STATA byly následně nově vytvořené kategorie překódovány tak, aby se s nimi lépe pracovalo. Dále byl vytvořen nový model, který zahrnoval veličiny kategorizované a veličiny spojité, tedy rentabilitu aktiv, přidanou hodnotu k tržbám a běžnou zadluženost. Odhadnutý model je zachycen následující Tab. 4.4.

Tab. 4.4: Model predikce úpadku (1)

Logistic regression				Number of obs	=	241
				LR chi2(8)	=	116.75
				Prob > chi2	=	0.0000
Log likelihood = -104.44928				Pseudo R2	=	0.3585
bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
roa	-2.811948	1.218524	-2.31	0.021	-5.200211	-.4236846
bezna_zadl~t	1.928909	.5205429	3.71	0.000	.9086639	2.949154
phtrzby	1.237811	.8945993	1.38	0.166	-.5155718	2.991193
kat_uvery~2	.9446863	.4482933	2.11	0.035	.0660474	1.823325
kat_uvery~a3	1.15912	.446853	2.59	0.009	.2833045	2.034936
kat_okamzi~1	-1.403355	.5217521	-2.69	0.007	-2.42597	-.3807393
kat_okamzi~2	-2.393546	.5457204	-4.39	0.000	-3.463139	-1.323954
kat_okamzi~3	-2.939018	.6555036	-4.48	0.000	-4.223782	-1.654255
_cons	-.5480414	.6784939	-0.81	0.419	-1.877865	.7817823

Zdroj: Vlastní zpracování v programu STATA

Z Tab. 4.4 je patrné, že při zahrnutí všech veličin se jako statisticky nevýznamný na základě z-statistiky jeví ukazatel PH/tržby. Z tohoto důvodu byl v dalším kroku vytvořen nový model predikce úpadku (2) a to bez zahrnutí této statisticky nevýznamné veličiny. Výsledek je zachycen v Tab. 4.5.

Tab. 4.5: Model predikce úpadku (2)

Logistic regression				Number of obs	=	277
				LR chi2(7)	=	129.34
				Prob > chi2	=	0.0000
Log likelihood = -125.59171				Pseudo R2	=	0.3399
bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
roa	-2.211428	1.012651	-2.18	0.029	-4.196188	-.2266678
bezna_zadl~t	1.718646	.4492835	3.83	0.000	.8380669	2.599226
kat_uvery~2	.7493089	.4055769	1.85	0.065	-.0456072	1.544225
kat_uvery~a3	1.270349	.4016121	3.16	0.002	.4832042	2.057495
kat_okamzi~1	-1.393823	.4656565	-2.99	0.003	-2.306493	-.4811529
kat_okamzi~2	-2.051543	.4826833	-4.25	0.000	-2.997585	-1.105501
kat_okamzi~3	-2.675028	.5854914	-4.57	0.000	-3.82257	-1.527486
_cons	-.2384059	.550537	-0.43	0.665	-1.317439	.8406268

Zdroj: Vlastní zpracování v programu STATA

Z Tab. 4.5 je zřejmé, že k výraznějším změnám ve statistické významnosti vysvětlujících proměnných nedošlo, zhoršila se nepatrně významnost pouze u druhé kategorie ukazatele úvěry/pasiva. Přesto lze tuto kategorii považovat za významnou, byla tedy v modelu ponechána. Na základě této tabulky však nebylo možné rozhodnout, zda je druhý model lepší pro predikci bankrotu než model předchozí, proto byl druhý model otestován vůči prvnímu testem pravděpodobnostním poměrem. Naskytl se však problém, neboť podmínkou použití tohoto testu je stejný počet pozorování, což v tomto případě splněno nebylo. Při vypuštění ukazatele PH/tržby došlo ke zmírnění omezujících podmínek, což zvýšilo počet firem ve sledovaném vzorku. Aby mohl být test použit, byla ve druhém modelu opět vložena omezující podmínka, která byla součástí prvního modelu predikce. To zaručilo komparaci obou modelů pomocí testu pravděpodobnostním poměrem. Výsledek uvádí Tab. 4.6.

Tab. 4.6: Test pravděpodobnostním poměrem

Likelihood-ratio test		LR chi2(1) = 1.94	
(Assumption: $\chi^2$ nested in <u>LRTEST_1_model</u> )		Prob > chi2 = 0.1642	

Zdroj: Vlastní zpracování v programu STATA

Test pravděpodobnostním poměrem porovnává první (složitější) model vůči druhému (jednoduššímu) modelu. Sledována je přitom hodnota označena jako Prob > chi2, která vyjadřuje statistickou významnost prvního modelu vůči druhému. Pokud je tato hodnota nižší než 0,05, je první model statisticky významnější než model druhý. V tomto případě je hodnota vyšší než doporučená 0,05, první model tedy není statisticky významnější než druhý model a pro predikci úpadku jsou tak oba modely považovány za ekvivalentní, jinak řečeno, rozdíl mezi výsledky získanými těmito dvěma modely není statisticky významný. Na základě těchto skutečností se dále

pracovalo se zjednodušeným modelem predikce úpadku s vynecháním ukazatele PH/tržby, tedy s modelem predikce úpadku (2).

#### 4.5. Hodnocení modelu

Ke zhodnocení spolehlivosti při predikování finanční tísně firmy modelem predikce úpadku (2) posloužily výsledky uvedené v Tab. 4.7.

Tab. 4.7: Klasifikační tabulka


Logistic model for bankrupt			
Classified	True		Total
	D	~D	
+	93	28	121
-	30	126	156
Total	123	154	277
Classified + if predicted $Pr(D) \geq .5$ True D defined as bankrupt != 0			
Sensitivity	$Pr(+ D)$		75.61%
Specificity	$Pr(- \sim D)$		81.82%
Positive predictive value	$Pr(D +)$		76.86%
Negative predictive value	$Pr(\sim D -)$		80.77%
False + rate for true ~D	$Pr(+ \sim D)$		18.18%
False - rate for true D	$Pr(- D)$		24.39%
False + rate for classified +	$Pr(\sim D +)$		23.14%
False - rate for classified -	$Pr(D -)$		19.23%
Correctly classified			79.06%

Zdroj: Vlastní zpracování v programu STATA

Na základě hodnot klasifikační tabulky můžeme o testovaném predikčním modelu bankrotu prohlásit, že jeho úspěšnost predikce je 79,06%. V 93 z 123 případů (v 75,61%), kdy došlo ke krachu společnosti, model tuto situaci identifikoval správně, ve zbylých 30 případech (24,39%) tuto situaci odhadl chybně. V 154 případech, kdy společnost nezkrachovala, odhadl tuto skutečnost v 126 případech správně (81,82%), mýlil se v 28 případech (18,18%).

Grafickým znázorněním klasifikační tabulky je následující Obr. 4.3, který zachycuje vztah mezi senzitivitou (vyjadřuje počet případů, kdy model správně určil bankrot) a specificitou (vyjadřuje počet případů, kdy model správně určil, že k bankrotu nedošlo).


Obr. 4.3: Vztah mezi senzitivitou a specificitou výsledného modelu



Zdroj: Vlastní zpracování v programu STATA

Na dalším Obr. 4.4 vidíme zkonstruovanou křivku *ROC*, která vyjadřuje vztah mezi senzitivitou a  $100 - \text{specificitou}$ .

Obr. 4.4: Křivka *ROC*



Zdroj: Vlastní zpracování v programu STATA

Křivka *ROC* se na Obr. 4.4 přibližuje levému hornímu rohu, což značí vysokou spolehlivost predikčního modelu při predikci úpadků společností. Pro hodnocení modelu je vhodné použít i ukazatel *AUC*, neboli plochu pod křivkou *ROC*. Tato hodnota je uvedena v Obr. 4.4 pod křivkou *ROC* a činí 0,8668, což se velmi blíží ideální hodnotě, kterou je hodnota 1.

Vytvořený model nebude uživateli nápomocen, pokud nebude správně interpretován. Jako podklad k interpretaci poslouží následující Tab. 4.8.

Tab. 4.8: Odds ratio

Logistic regression				Number of obs	=	277
				LR chi2(7)	=	129.34
				Prob > chi2	=	0.0000
Log likelihood = -125.59171				Pseudo R2	=	0.3399
bankrot	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
roa	.1095441	.11093	-2.18	0.029	.0150528	.7971855
bezna_zadl~t	5.576974	2.505642	3.83	0.000	2.311893	13.45332
kat_okamzi~1	.248125	.115541	-2.99	0.003	.09961	.6180704
kat_okamzi~2	.1285364	.0620424	-4.25	0.000	.0499075	.331045
kat_okamzi~3	.0689049	.0403432	-4.57	0.000	.0218715	.2170807
kat_uvery~2	2.115537	.8580131	1.85	0.065	.9554172	4.68434
kat_uvery~a3	3.562097	1.430581	3.16	0.002	1.621261	7.826338

Zdroj: Vlastní zpracování v programu STATA

Odds ratio je podílem šancí (dvou odds) pro dvě různé hodnoty nezávisle proměnných. V případě kategoriálních proměnných je hodnota odds ratio interpretována k referenční hodnotě, kterou je tzv. nultá kategorie. U ukazatele úvěry/pasiva je interpretace následující: jestliže je podíl úvěrů na pasivech větší než 0,00159% a zároveň menší než cca 15,6%, je šance bankrotu společnosti 2,115537 krát větší než u společnosti, která má hodnotu úvěrů menší než 0,00159%. Přesahuje-li podíl úvěrů na pasivech hranici 15,6%, je šance bankrotu 3,562097 větší než u podniku s hodnotou úvěrů menší než 0,00159%. U tohoto ukazatele došlo ke splynutí nulté a první kategorie, obě byly tudíž považovány za referenční.

Bude-li okamžitá likvidita podniku přesahovat hranici cca 0,0245, je šance finančních problémů firmy 0,248125 krát větší, než kdyby tato likvidita byla menší než zmiňovaných 0,0245. Je-li okamžitá likvidita vyšší než cca 0,1292, je šance defaultu firmy 0,1285364 krát větší než u společnosti, která má okamžitou likviditu menší než 0,0245. Společnost s okamžitou likviditou větší než 0,6154 může počítat s šancí bankrotu 0,0689049 krát větší než společnost, která má okamžitou likviditu menší než 0,0245. Jinými slovy lze říci, že u podniku s větší okamžitou likviditou je riziko úpadku menší, neboť uvedené šance jsou menší než 1.


U nekategoriálních proměnných se interpretace odds ratio liší, neexistuje totiž žádná referenční hodnota, vůči které bychom směli porovnávat. V případě rentability aktiv můžeme na základě modelu tvrdit, že zvýší-li se hodnota ROA o jednotku, dojde k růstu šance bankrotu o 0,10954101 jednotek. Obdobně je tomu u ukazatele běžná



zadluženost. Vzroste-li zadluženost o jednotku, vzroste šance bankrotu o 5,576974 jednotek.

Grafické znázornění odds ratio včetně intervalů spolehlivosti jsou zobrazeny následujícími Obr. 4.5-8. U kategoriální proměnných byly hodnoty převzaty z Tab. 4.8, u spojitých proměnných (rentabilita aktiv a běžná zadluženost) byly výchozí hodnoty převzaty z Tab. 4.5. Hodnoty odds ratio u spojitých proměnných byly spočteny jako  $odds\ ratio(c) = \exp(c \cdot \hat{\beta}_1)$ , kde  $c$  vyjadřuje změnu, tzn. růst, nebo pokles hodnoty poměrového ukazatele o jednotku a  $\hat{\beta}_1$  je odhad koeficientu daného ukazatele z Tab. 4.5. Intervaly spolehlivosti v případě spojitých proměnných byly vypočteny dle vzorce  $\exp\left[c \cdot \hat{\beta}_1 \pm z_{1-\alpha/2} \cdot \hat{s}(\hat{\beta}_1)\right]$ , kde  $z_{1-\alpha/2}$  je příslušný kvantil normovaného normálního rozdělení a  $\hat{s}(\hat{\beta}_1)$  značí odhad směrodatné odchylky odhadu daného koeficientu, který byl převzat z Tab. 4.5.


Obr. 4.5: Odds ratio pro ukazatel rentability aktiv ROA



Zdroj: Vlastní zpracování

Z Obr. 4.5 můžeme sledovat, že šance bankrotu podniku klesá s rostoucí rentabilitou aktiv. Doporučením pro firmy tedy je, aby zvyšovaly hodnotu provozního zisku k neklesajícím aktivům.


Obr. 4.6: Odds ratio pro ukazatel běžná zadluženost



Zdroj: Vlastní zpracování

S rostoucí běžnou zadlužeností roste šance bankrotu společnosti, jak můžeme vyčíst na základě Obr. 4.6. Při zvýšení běžné zadluženosti o dvě jednotky dochází růstu šance bankrotu o více než třicet jednotek, což svědčí o významnosti optimalizace finančních zdrojů.

Obr. 4.7: Odds ratio pro ukazatel okamžité likvidity




Zdroj: Vlastní zpracování

Obr. 4.7 znázorňuje klesající šanci existenčních problému v případě růstu okamžité likvidity. Hranice první kategorie představuje hodnotu likvidity ve výši 0,0245, druhá kategorie začíná na hodnotě 0,1292 a hranice třetí kategorie je od

hodnoty 0,6154. Solventnost podniku patří k nejdůležitějším požadavkům při řízení a investičním rozhodování v podniku.

Obr. 4.8: Odds ratio pro ukazatel úvěry/pasiva



Zdroj: Vlastní zpracování

I na posledním z grafů jsou zobrazeny odds ratio ukazatele úvěry/pasiva. Můžeme sledovat, že s rostoucím podílem úvěrů k pasivům roste podíl šancí finanční tísně podniku. Odds ratio pro druhou kategorii platí pro zadluženost, která je nad hranicí 0,00159%, hranice třetí kategorie začíná na hranici 15,6%. Opět je třeba zamyslet se nad optimalizací kapitálové struktury podniku.

Finální model predikce úpadku můžeme na základě Tab. 4.5 zapsat následovně

$$\pi = \frac{e^{-0,24-2,21x_1+1,72x_2+0,75x_{31}+1,27x_{32}-1,39x_{41}-2,05x_{42}-2,68x_{43}}}{1 + e^{-0,24-2,21x_1+1,72x_2+0,75x_{31}+1,27x_{32}-1,39x_{41}-2,05x_{42}-2,68x_{43}}},$$

kde  $x_1$  je ukazatel ROA,  $x_2$  značí běžnou zadluženost,  $x_{31}$  je druhá kategorie ukazatele úvěry/pasiva,  $x_{32}$  je třetí kategorie ukazatele úvěry/pasiva,  $x_{41}$  je první kategorie okamžité likvidity,  $x_{42}$  druhá kategorie okamžité likvidity a  $x_{43}$  je třetí kategorie okamžité likvidity. Jednotlivé koeficienty  $\beta_j$  musely být z důvodu rozsahu zaokrouhleny na dvě desetinná místa.

#### 4.6. Ověření modelu

Pro zjištění, jak model predikce úpadku firem skutečně funguje na reálných datech, bylo nalezeno nových 29 firem, které se v průběhu roku 2009 dostaly do finančních potíží, ale rovněž několik firem, které v danou dobu problémy neměly. Finanční výkazy těchto společností byly opět staženy z databáze MagnusWeb od společnosti ČEKIA a to za účetní období roku 2008. Po provedení finanční analýzy firem byl následně aplikován model predikce úpadku a to s výsledkem, který uvádí Tab. 4.9.

Tab. 4.9: Ověření modelu predikce úpadku

Počet správně určených firem	17	58,62%
Počet chybně určených firem	5	17,27%
Počet firem v šedé zóně (od 0,35 do 0,65)	7	24,14%
Počet firem celkem	29	100%

Zdroj: Vlastní zpracování

Z Tab. 4.9 je patrné, že úspěšnost modelu v predikování úpadku na reálných datech je přibližně 59%. Chybně bylo modelem stanoveno pět firem, které buď měly problémy a model je neodhalil, nebo jim mylně přiřadil vysokou pravděpodobnost bankrotu. U sedmi společností nebyla budoucí finanční situace podniku modelem rozpoznána. Model tyto firmy zařadil do šedé zóny, jejíž interval byl určen subjektivně a to tak, aby byl rovnoměrně rozložen okolo středu, tj. okolo hodnoty 0,5.

Tab. 4.10 jen pro srovnání uvádí výsledky, kterých bylo dosaženo na stejných datech při aplikaci Altmanova modelu.

Tab. 4.10: Výsledky predikce úpadku aplikací Altmanova modelu

Počet správně určených firem	16	55,17%
Počet chybně určených firem	6	20,69%
Počet firem v šedé zóně (od 1,2 do 2,9)	7	24,14%
Počet firem celkem	29	100%

Zdroj: Vlastní zpracování

Na základě hodnot uvedených v Tab. 4.10 vidíme, že při predikci bankrotu firem pomocí Altmanova modelu bylo dosaženo ekvivalentních výsledků jako při aplikaci modelu predikce úpadku. Lze dokonce tvrdit, že v tomto případě je Altmanův model nepatrně horší v předpovídání finančních problémů společností. Tento poznatek však nemůže být brán jako objektivní fakt, neboť testovaný vzorek je velmi malý.

## 5. ZÁVĚR

Cílem práce bylo vytvořit fungující scoringový model pro predikci úpadku firem na českém podnikatelském trhu. K vytvoření modelu byla použita data získaná z databáze MagnusWeb od společnosti ČEKIA. Konkrétně šlo o finanční výkazy čtyř set podnikatelských subjektů, zejména akciových společností a společností s ručením omezeným, případně několika bytových družstev. Finanční výkazy obsahovaly data za účetní období roku 2008. Polovinu ze čtyř set firem tvořily podniky, které se v průběhu roku 2009 dostaly do finančních problémů, jež měly za následek prohlášení konkurzu, zahájení insolventního řízení, prohlášení úpadku apod.

Model predikce úpadku byl vytvořen statistickou metodou logistické regrese, což je zvláštní typ regresní analýzy, neboť v tomto případě je na straně vysvětlované proměnné dichotomická, nebo multinomická veličina, která nabývá pouze malého množství obměn. Předpokladem pro použití logistické regrese bylo provedení finanční analýzy u zmíněných čtyř set podniků. Za tímto účelem bylo vybráno dvacet poměrových ukazatelů. Po výpočtu finanční analýzy byl z poměrových ukazatelů vyloučen ukazatel rentability vlastního kapitálu, neboť získané hodnoty byly zkreslené z důvodu záporného vlastního kapitálu u mnoha firem. Dále bylo vyloučeno 28 společností, které v průběhu roku nevykazovaly žádné tržby, což ztěžovalo výpočty těch ukazatelů, kde se výše tržeb vyskytovala ve jmenovali.

Výsledky finanční analýzy posloužily jako vstupní údaje pro vytvoření modelu ve statistickém programu STATA, ve kterém probíhaly veškeré další výpočty včetně tvorby grafů. Po jednorozměrné analýze, kterou bylo zjištěno, zda daný poměrový ukazatel je pro budoucí predikci úpadku firmy statisticky významný, bylo vyloučeno jedenáct poměrových ukazatelů. Následně byla provedena vícerozměrná analýza, neboli metoda stepwise regression, při které byly do modelu zahrnuty všechny proměnné najednou. Bylo tak odhaleno, že mezi některými proměnnými existují vzájemné interakce, což vedlo k dalšímu vyloučení tří poměrových ukazatelů. U zbylých pěti veličin bylo pomocí frakčního polynomu zjišťováno, zda lze vliv logitu na vysvětlovanou proměnnou zobrazit jako lineární funkci, nebo je-li třeba danou veličinu převést na kategoriální. Kategorizovány nakonec byly ukazatel úvěry/pasiva a okamžitá likvidita. Následovalo vytvoření prvního modelu predikce úpadku, kde se na základě z-statistiky stal ukazatel PH/tržby statisticky nevýznamným. Byl tedy znovu vytvořen model predikce úpadku bez zahrnutí této nezávisle proměnné a oba modely byly vůči

sobě otestovány testem pravděpodobnostním poměrem, který prokázal, že rozdíl mezi oběma modely není statisticky významný. Pro predikci úpadku firem postačuje tedy druhý vytvořený model se čtyřmi nezávisle proměnnými, z nichž jsou dvě spojité a dvě kategoriální.

K hodnocení modelu byla využita klasifikační tabulka, na základě které bylo zjištěno, že spolehlivost modelu v predikci úpadku je 79,06%. Grafickým hodnocením modelu byla konstrukce křivky *ROC*, která se velmi blížila levému hornímu rohu, což svědčí o vysoké spolehlivosti modelu. Tato spolehlivost byla potvrzena i ukazatelem *AUC*, jehož hodnota činí 0,86.

Výsledný model byl interpretován pomocí ukazatele odds ratio, který je podílem šancí (odds) pro dvě různé hodnoty nezávisle proměnných. Pro názornost odds ratio každé nezávisle proměnné byly zpracovány i přehledné grafy. V závěru praktické části byl model ověřen na nově získaných reálných datech. Úspěšnost predikce modelu na těchto datech činila přibližně 59%, v 17% model chybně predikoval bankrot a v 24% model nedokázal definovat budoucí finanční situaci podniku. Pro zajímavost byl na stejných reálných datech otestován i Altmanův model predikce úpadku. Srovnáním obou modelů se dospělo k závěru, že modely jsou ekvivalentní, spolehlivost v predikci byla nepatrně horší u Altmanova modelu.

Závěrem lze říci, že námi vytvořený model je vhodný pro předpovídání možných finančních problémů firem, avšak musíme mít na paměti, že tento ani žádný jiný predikční model nefunguje se 100% spolehlivostí a jeho výsledek by se tak neměl stát jediným kritériem pro hodnocení a předpovídání finančního zdraví společnosti. Nevýhodou modelu je to, že nedovede pracovat s extrémně odlehlými hodnotami. Extrémní hodnoty však již samy o sobě svědčí o tom, že v podniku není vše zcela v pořádku. Za druhou nevýhodu modelu lze považovat i data, která byla pro sestavení modelu použita a která s velkou pravděpodobností měla za následek nižší spolehlivost při predikování finančních obtíží. Rok 2008 byl v České republice rokem, kdy se u nás projevil důsledek světové finanční krize, která pro mnohé podniky znamenala v lepším případě snížení tržeb, zisku, odbytu, vznik ztráty, v horším případě krach společnosti. K vytvoření úspěšnějšího modelu by bylo tedy potřeba finančních výkazu většího množství firem a to za různé roky, kdy se ekonomice dařilo i nedařilo. Nešvarem českých podnikatelských subjektů je však nízká informační otevřenost a ochota v poskytování finančních výkazu, ačkoli je tato povinnost dána zákonem.

## SEZNAM POUŽITÉ LITERATURY

- 1) BLAHA, Z. S., JINDŘICHOVSKÁ, I. *Jak posoudit finanční zdraví firmy*. 3. rozš. vyd. Praha: Management Press, s.r.o., 2006. 194 s. ISBN 80-7261-145-3.
- 2) BRABCOVÁ, H. *Využití logistické regrese ve výzkumu trhu* [online]. Praha, 2010. 78 s. Diplomová práce. Vysoká škola ekonomická v Praze. Dostupné z WWW: <[https://www.ue-prague.eu/vskp/public.php?evskp\\_id=23264](https://www.ue-prague.eu/vskp/public.php?evskp_id=23264)>.
- 3) CRAMER, J. S. *Logit Models from Economics and Other Fields*. 2nd edition. Cambridge: Cambridge University Press, 2003. 184 s. ISBN 0521815886.
- 4) DLUHOŠOVÁ, D. *Finanční řízení a rozhodování podniku: Analýza, Investování, Oceňování, Riziko, Flexibilita*. 1. vyd. Praha: EKOPRESS, s.r.o., 2006. 192 s. ISBN 80-86119-58-0.
- 5) GOURIEROUX, CH.; JASIAK, J. *The Econometrics of Individual Risk: Credit, Insurance, and Marketing*. New Jersey: Princeton University Press, 2007. 256 s. ISBN 0691120668.
- 6) HEBÁK, P., et al. *Vícerozměrné statistické metody (1)*. 1. vyd. Praha: INFORMATORIUM, 2004. 239 s. ISBN 80-7333-025-3.
- 7) HEBÁK, P., et al. *Vícerozměrné statistické metody (2)*. 1. vyd. Praha: INFORMATORIUM, 2005. 239 s. ISBN 80-7333-036-9.
- 8) HEBÁK, P., et al. *Vícerozměrné statistické metody (3)*. 2. vyd., doplněné. Praha: INFORMATORIUM, 2007. 271 s. ISBN 978-80-7333-001-9.
- 9) HOSMER, D. W.; LEMESHOW, S. *Applied Logistic Regression*. 2nd edition. New York: Wiley-Interscience, 2000. 392 s. ISBN 0471356328.
- 10) KISLINGEROVÁ, E., HNILICA, J. *Finanční analýza krok za krokem*. 1. vyd. Praha: C.H. Beck, 2005. 138 s. ISBN 80-7179-321-3.
- 11) PEČÁKOVÁ, I. *Logistická regrese s vícekategoriální vysvětlovanou proměnnou*. Acta Oeconomica Pragensia, VŠE Praha, 2007. Roč. 15, č.1, s. 86-86. ISSN 1804-2112.

- 12) RŮČKOVÁ, P. *Finanční analýza*. 1. vyd. Praha: Grada Publishing, 2007. 118 s. ISBN 978-80-247-1386-1.
- 13) SEDLÁČEK, J. *Finanční analýza podniku: Metody finanční analýzy, Horizontální, vertikální a indexová analýza, Bonitní a bankrotní modely, Cash flow a rating*. 1. vyd. Brno: Computer Press, a.s., 2007. 154 s. ISBN 978-80-251-1830-6.
- 14) SLIVKOVÁ, E. *Souhrnné hodnocení finanční úrovně podniku* [online]. Ostrava, 2009. 53 s. Bakalářská práce. Vysoká škola Báňská – Technická univerzita Ostrava. Dostupné z WWW: <<http://dspace.vsb.cz/dspace/handle/10084/72979>>.
- 15) STANKOVIČOVÁ, I.; VOJTKOVÁ, M. *Viacrozmerné štatistické metódy s aplikáciami*. 1.vyd. Bratislava : Iura edition, 2007. 89 s. ISBN 978-80-8078-152.
- 16) VALACH, J. a kol.: *Finanční řízení podniku*. 1.vyd. Praha: Ekopress, 1997. 247 s. ISBN 80-901991-6-X.
- 17) VOSOBA, P., et al. *Řízení firemních financí: Aktivní využívání firemních zdrojů*. 1. vyd. Praha: EKOPRESS, s.r.o., 1998. 214 s. ISBN 80-86119-05-X.
- 18) VRANÁ, P. *Skóring* [online]. [s.l.], 2009. 9 s. Semestrální práce. Západočeská univerzita v Plzni. Dostupné z WWW: <[http://num.kma.zcu.cz/galerie/MAB-prace/Galerie%20MAB%202009/Skoring%20\(Vrana\).pdf](http://num.kma.zcu.cz/galerie/MAB-prace/Galerie%20MAB%202009/Skoring%20(Vrana).pdf)>.

#### **Internetové zdroje:**

- 1) ČEKIA [online]. 2001-2011 [cit. 2011-03-20]. MagnusWeb. Dostupné z WWW: <<http://www.cekia.cz/magnusweb/>>.
- 2) Insolvenční rejstřík [online]. 2008 [cit. 2011-03-20]. Dostupné z WWW: <<https://isir.justice.cz/isir/common/index.do>>.
- 3) Ministerstvo spravedlnosti České republiky [online]. 2011 [cit. 2011-03-20]. Obchodní rejstřík a Sbírka listin. Dostupné z WWW: <<http://www.justice.cz/xqw/xervlet/insl/index?sysinf.@typ=or&sysinf.@strana=searchSubject>>.



- 4) ŘEZÁNKOVÁ, H. BADAME.VSE.CZ [online]. 2006 [cit. 2011-03-20]. Postupy používané při analýze dat. Dostupné z WWW: <<http://badame.vse.cz/clanky/analyza-dat.php>>.
- 5) ŘEZÁNKOVÁ, H.; MAREK, L.; VRABEC, M. Regrese a korelace [online]. 2001 [cit. 2011-03-20]. IAstat - Interaktivní učebnice statistiky. Dostupné z WWW: <<http://iastat.vse.cz/regrese/Regrese5.htm>>.
- 6) Wikipedie [online]. 2010 [cit. 2011-03-20]. Diskriminační analýza. Dostupné z WWW: <[http://cs.wikipedia.org/wiki/Diskrimina%C4%8Dn%C3%AD\\_anal%C3%BDza](http://cs.wikipedia.org/wiki/Diskrimina%C4%8Dn%C3%AD_anal%C3%BDza)>.

## SEZNAM TABULEK A OBRÁZKŮ

Tab. 3.1: Hodnocení dle Indexu bonity .....	35
Tab. 4.1: Statistická významnost vlivu daného ukazatele na bankrot firmy .....	39
Tab. 4.2: Stepwise regression .....	43
Tab. 4.3: Frakční polynomy.....	44
Tab. 4.4: Model predikce úpadku (1) .....	46
Tab. 4.5: Model predikce úpadku (2) .....	47
Tab. 4.6: Test pravděpodobnostním poměrem .....	47
Tab. 4.7: Klasifikační tabulka.....	48
Tab. 4.8: Odds ratio .....	50
Tab. 4.9: Ověření modelu predikce úpadku.....	54
Tab. 4.10: Výsledky predikce úpadku aplikací Altmanova modelu.....	54
Obr. 3.1: Symetrická s-křivka.....	25
Obr. 3.2: Vztah senzitivity a specifcity .....	33
Obr. 3.3: Křivka <i>ROC</i> .....	33
Obr. 4.1: Pravděpodobnost vzniku bankrotu na hodnotě daného ukazatele.....	41
Obr. 4.2: Grafické testování linearity logitů .....	45
Obr. 4.3: Vztah mezi senzitivitou a specifcitou výsledného modelu .....	49
Obr. 4.4: Křivka <i>ROC</i> .....	49
Obr. 4.5: Odds ratio pro ukazatel rentability aktiv ROA.....	51
Obr. 4.6: Odds ratio pro ukazatel běžná zadluženost .....	52
Obr. 4.7: Odds ratio pro ukazatel okamžité likvidity .....	52
Obr. 4.8: Odds ratio pro ukazatel úvěry/pasiva .....	53

## SEZNAM ZKRATEK

<b>AUC</b>	Area Under ROC Curve
<b>EAT</b>	Čistý zisk
<b>EBIT</b>	Výsledek hospodaření před zdaněním a úroky
<b>EBITDA</b>	Výsledek hospodaření před daněmi, úroky a odpisy
<b>EBT</b>	Výsledek hospodaření před zdaněním
<b>OA</b>	Oběžná aktiva
<b>PH</b>	Přidaná hodnota
<b>ROA</b>	Rentabilita aktiv
<b>ROC</b>	Rentabilita tržeb
<b>ROCE</b>	Rentabilita dlouhodobých zdrojů
<b>ROE</b>	Rentabilita vlastního kapitálu

## PROHLÁŠENÍ O POUŽITÍ VÝSLEDKŮ DIPLOMOVÉ PRÁCE

Prohlašuji, že

- jsem byla seznámena s tím, že na mou diplomovou práci se plně vztahuje zákon č. 121/2000 Sb. – autorský zákon, zejména § 35 – užití díla v rámci občanských a náboženských obřadů, v rámci školních představení a užití díla školního a § 60 – školní dílo;
- беру на ве́доміі, že Vysoká škola báňská – Technická univerzita Ostrava (dále jen VŠB-TUO) má právo nevýdělečně, ke své vnitřní potřebě, diplomovou práci užít (§ 35 odst.3);
- souhlasím s tím, že diplomová práce bude v elektronické podobě archivována v Ústřední knihovně VŠB-TUO a jeden výtisk bude uložen u vedoucího diplomové práce. Souhlasím s tím, že bibliografické údaje o diplomové práci budou zveřejněny v informačním systému VŠB-TUO;
- bylo sjednáno, že s VŠB-TUO, v případě zájmu z její strany, uzavřu licenční smlouvu s oprávněním užít dílo v rozsahu § 12 odst. 4 autorského zákona;
- bylo sjednáno, že užít své dílo, diplomovou práci, nebo poskytnout licenci k jejímu využití mohu jen se souhlasem VŠB-TUO, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly VŠB-TUO na vytvoření díla vynaloženy (až do jejich skutečné výše).

V Ostravě dne 29. dubna 2011

---

jméno a příjmení studenta

Adresa trvalého pobytu studenta:

Strahovice 168, 747 24

## **PŘÍLOHY**

Příloha č.1: Jednorozměrná analýza 19 ukazatelů

Příloha č.2: Frakční polynomy

## Příloha č.1: Jednorozměrná analýza 19 ukazatelů

## Logistic regression

Number of obs = 371

LR  $\chi^2(1) = 36.71$

Prob > chi2	=	0.0000
-------------	---	--------

Pseudo R2 = 0.0717

Log likelihood = -237.66754

bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
roaebitda	-1.058863	.2875574	-3.68	0.000	-1.622465	-.4952609
_cons	-.2168417	.1087471	-1.99	0.046	-.4299821	-.0037014

## Logistic regression

Number of obs = 371

LR chi2(1) = 35,86

Prob > chi2	=	0.0000
-------------	---	--------

Pseudo R2 = 0.0700

Log likelihood = -238.0933

bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
roa	-1.005582	.2759963	-3.64	0.000	-1.546525	-.4646393
_cons	-.2565602	.1091568	-2.35	0.019	-.4705035	-.0426168

## Logistic regression

Number of obs = 372

```

Number of obs      =          372
LR chi2(1)         =        25.15

```

Prob > chi2	=	0.0000
-------------	---	--------

Pseudo R2 = 0.0490

Log likelihood = -244.22051

bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
ros	-.6625006	.224541	-2.95	0.003	-1.102593	-.2224083
_cons	-.2673828	.1083904	-2.47	0.014	-.4798242	-.0549414

## Logistic regression

Number of obs = 371

LR  $\chi^2(1) = 74.45$

Prob &gt; chi2 = 0.0000

Pseudo R2 = 0.1454

Log likelihood = -218.79728

bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
celkova_zat	<b>1.052427</b>	<b>.1948198</b>	<b>5.40</b>	<b>0.000</b>	<b>.6705873</b>	<b>1.434267</b>
_cons	<b>-1.21202</b>	<b>.2039347</b>	<b>-5.94</b>	<b>0.000</b>	<b>-1.611725</b>	<b>-.8123153</b>

## Logistic regression

Number of obs = 371

LR  $\chi^2(1) = 26.96$

Prob > chi2	=	0.0000
-------------	---	--------

Pseudo R2 = 0.0527

Log likelihood = -242.54325

bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
uverypasiva	<b>1.976876</b>	<b>.5138765</b>	<b>3.85</b>	<b>0.000</b>	<b>.9696965</b>	<b>2.984055</b>
_cons	<b>-.4479498</b>	<b>.1235002</b>	<b>-3.63</b>	<b>0.000</b>	<b>-.6900057</b>	<b>-.2058939</b>

```
Number of obs      =      372
LR chi2(1)         =      3.92
Prob > chi2        =     0.0478
Pseudo R2          =     0.0076
```

Pseudo R2 = 0.0076

bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
dob_a_obrat~b	.0016415	.0009768	1.68	0.093	-.0002731	.003556
_cons	-.2212141	.1110156	-1.99	0.046	-.4388006	-.0036276

```
Number of obs      =      372
LR chi2(1)         =      3.73
Prob > chi2        =     0.0535
Pseudo R2          =     0.0073
```

Pseudo R2 = 0.0073

bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
doba_obrat~k	.0000602	.0000492	1.22	0.221	-.0000363	.0001567
_cons	-.1796615	.1054665	-1.70	0.088	-.3863722	.0270491

```
Number of obs    =      372
LR chi2(1)       =      3.60
Prob > chi2      =     0.0579
Pseudo R2       =     0.0070
```

Pseudo R2 = 0.0070

bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
dob_a_obrat~v	.0000115	.0000103	1.11	0.267	-8.79e-06	.0000317
_cons	-.1800681	.1056789	-1.70	0.088	-.387195	.0270587

```
Number of obs    =      372
LR chi2(1)       =      64.66
Prob > chi2      =      0.0000
Pseudo R2       =      0.1259
```

Pseudo R2	=	0.1259
-----------	---	--------

bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
bezna_likv~a	-.4136021	.0847603	-4.88	0.000	-.5797291	-.247475
_cons	.6471002	.1702415	3.80	0.000	.313433	.9807674

```
Number of obs    =      372
LR chi2(1)       =      59.59
Prob > chi2      =      0.0000
Pseudo R2       =      0.1160
```

Pseudo R2 = 0.1160

bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
pohotova_l~a	-.4086848	.0878191	-4.65	0.000	-.580807	-.2365626
_cons	.5164261	.1553399	3.32	0.001	.2119654	.8208867

```
Number of obs    =      372
LR chi2(1)       =      75.84
Prob > chi2      =      0.0000
Pseudo R2       =      0.1477
```

Pseudo R2 = 0.1477

bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
okamzita_l~a	-1.008599	.2004571	-5.03	0.000	-1.401487	-.61571
_cons	.4250051	.1337747	3.18	0.001	.1628116	.6871987

```
Number of obs    =      371
LR chi2(1)       =      25.61
Prob > chi2      =      0.0000
Pseudo R2       =      0.0500
```

Pseudo R2 = 0.0500

bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
pomerovy_u~y	-.223129	.0778214	-2.87	0.004	-.3756563	-.0706018
_cons	-.2413847	.1074736	-2.25	0.025	-.4520291	-.0307403

```
Number of obs    =      372
LR chi2(1)       =      25.78
Prob > chi2      =      0.0000
Pseudo R2       =      0.0502
```

Pseudo R2 = 0.0502

bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
phtrzby	-1.154096	.3298242	-3.50	0.000	-1.80054	-.5076525
_cons	.0166205	.1238963	0.13	0.893	-.2262117	.2594528

Number of obs	=	372
LR chi2(1)	=	0.00
Prob > chi2	=	0.9457
Pseudo R2	=	0.0000

Pseudo R2 = 0.0000

bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
financni_p~a	.0001158	.0016982	0.07	0.946	-.0032126	.0034442
_cons	-.1517333	.1048465	-1.45	0.148	-.3572287	.053762

```
Number of obs    =      372
LR chi2(1)       =       2.75
Prob > chi2      =    0.0972
Pseudo R2       =    0.0054
```

Pseudo R2 = 0.0054

bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
urokove_zai	-.1809646	.1306642	-1.38	0.166	-.4370616	.0751324
_cons	-.1547818	.1043459	-1.48	0.138	-.359296	.0497324

```
Number of obs      =          297
LR chi2(1)         =          17.55
Prob > chi2         =          0.0000
Pseudo R2          =          0.0429
```

Pseudo R2 = 0.0429

bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
stupen_kry~v	-.0206089	.0086472	-2.38	0.017	-.0375572	-.0036606
_cons	-.1600305	.119793	-1.34	0.182	-.3948204	.0747594

```
Number of obs      =          371
LR chi2(1)         =       100.14
Prob > chi2        =       0.0000
Pseudo R2         =       0.1956
```

Pseudo R2	=	0.1956
-----------	---	--------

bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
bezna_zadl~t	2.013471	.2888069	6.97	0.000	1.44742	2.579522
_cons	-1.481581	.203975	-7.26	0.000	-1.881365	-1.081797



Logistic regression

Number of obs = 372  
 LR chi2(1) = 0.00  
 Prob > chi2 = 0.9515  
 Pseudo R2 = 0.0000

Log likelihood = -256.79414

bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
zadluzenos~u	.0001037	.0017054	0.06	0.952	-.0032388	.0034462
_cons	-.151529	.1046389	-1.45	0.148	-.3566173	.0535594

Logistic regression

Number of obs = 372  
 LR chi2(1) = 0.53  
 Prob > chi2 = 0.4665  
 Pseudo R2 = 0.0010

Log likelihood = -256.53083

bankrot	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
uverova_zat	.0046402	.0068962	0.67	0.501	-.0088761	.0181565
_cons	-.1533588	.1040961	-1.47	0.141	-.3573834	.0506657

## Příloha č.2: Frakční polynomy

Fractional polynomial model comparisons:

roa	df	Deviance	Dev. dif.	P (*)	Powers
Not in model	0	449.872	64.640	0.000	
Linear	1	392.853	7.621	0.055	1
m = 1	2	392.853	7.621	0.022	1
m = 2	4	385.232	—	—	3 3

Fractional polynomial model comparisons:

phtrzby	df	Deviance	Dev. dif.	P (*)	Powers
Not in model	0	405.841	23.089	0.000	
Linear	1	390.375	7.622	0.055	1
m = 1	2	385.503	2.751	0.253	0
m = 2	4	382.753	—	—	-2 .5

Fractional polynomial model comparisons:

uverypasiva	df	Deviance	Dev. dif.	P (*)	Powers
Not in model	0	481.308	28.420	0.000	
Linear	1	465.508	12.620	0.006	1
m = 1	2	453.630	0.742	0.690	0
m = 2	4	452.888	—	—	-2 -2

Fractional polynomial model comparisons:

bezna_zadl~t	df	Deviance	Dev. dif.	P (*)	Powers
Not in model	0	482.952	99.550	0.000	
Linear	1	389.111	5.709	0.127	1
m = 1	2	385.569	2.167	0.338	.5
m = 2	4	383.402	—	—	-.5 1

Fractional polynomial model comparisons:

okamzita_l~a	df	Deviance	Dev. dif.	P (*)	Powers
Not in model	0	450.518	114.380	0.000	
Linear	1	369.119	32.981	0.000	1
m = 1	2	347.940	11.803	0.003	.5
m = 2	4	336.138	—	—	-.5 0